



UNIVERSIDAD DE CHILE  
FACULTAD DE CIENCIAS FÍSICAS Y MATEMÁTICAS  
DEPARTAMENTO DE INGENIERÍA DE MINAS  
DEPARTAMENTO DE GEOLOGÍA

PLANIFICACIÓN DE CORTO PLAZO CONSIDERANDO INCERTIDUMBRE  
GEOLÓGICA Y RESTRICCIONES OPERACIONALES EN MINERÍA DE CIELO  
ABIERTO

TESIS PARA OPTAR AL GRADO DE MAGÍSTER EN MINERÍA

MEMORIA PARA OPTAR AL TÍTULO DE GEÓLOGO

MARIO CLAUDIO HINOJOSA MOLINA

PROFESOR GUÍA:  
NELSON MORALES VARELA

PROFESOR CO-GUÍA:  
BRIAN TOWNLEY CALLEJAS

MIEMBROS DE LA COMISIÓN:  
GONZALO NELIS SUAZO  
PIERRE NANCEL-PENARD  
ALDO QUELOPANA RETAMAL

SANTIAGO DE CHILE

2022

RESUMEN DE LA TESIS PARA OPTAR  
AL GRADO DE MAGÍSTER EN MINERÍA  
RESUMEN DE LA MEMORIA PARA OPTAR  
AL TÍTULO DE GEÓLOGO  
POR: MARIO CLAUDIO HINOJOSA MOLINA  
FECHA: 2022  
PROF. GUÍA: NELSON MORALES VARELA

## PLANIFICACIÓN DE CORTO PLAZO CONSIDERANDO INCERTIDUMBRE GEOLÓGICA Y RESTRICCIONES OPERACIONALES EN MINERÍA DE CIELO ABIERTO

La planificación minera corresponde al área de ingeniería de minas que se encarga de generar un programa de explotación, en distintos horizontes temporales, para obtener el mejor beneficio del proyecto. En el corto plazo de minería a cielo abierto se definen los polígonos de extracción que se generan a partir de *Selective Mining Units* (SMU). Estos son bloques de menor tamaño y que contienen información obtenida de los pozos de tronadura. El agendamiento de estos polígonos es complejo por restricciones operacionales, definición de destino y periodo de minado. En Nelis y Morales (2021a) se aborda este tema pero no se toma en cuenta la incertidumbre por ejemplo de ley o variable geometalúrgica.

En esta tesis, se emplea una metodología que genera polígonos de extracción, o clusters, y se estudia el efecto de la incertidumbre de los datos a través de distintos escenarios geológicos. Para ello, se utiliza un modelo de optimización cuyos parámetros de entrada son el modelo de bloques, tamaño y número máximo de clusters, un radio de búsqueda y parámetros económicos. Como resultado, se tiene una distribución de clusters, su agendamiento, destino y valor económico. Para estudiar el efecto de la incertidumbre se generan tres tipos de casos y múltiples pruebas. El primero es Determinista (DET) donde todos los escenarios utilizan el agendamiento del caso base. El segundo es Conocimiento Parcial (CPAR), en donde cada escenario tiene su propio agendamiento pero ligado al caso base. El tercero es Conocimiento Perfecto (CP) donde se genera un agendamiento considerando que cada escenario es independiente. Los casos de estudios anteriores se comparan entre sí y con un Agendamiento a Nivel de Bloque (ANB). Para finalizar, se hace un estudio utilizando curvas de recuperación metalúrgicas para estudiar su impacto en el agendamiento.

La metodología se aplica sobre un caso de estudio compuesto por dos bancos, con un total de 520 bloques y un periodo de agendamiento de 4 meses. Se hace una comparación de los resultados de las distintas pruebas de los casos DET y CPAR y se observa que en solo una prueba se tiene un promedio de valor económico DET mayor al CPAR. Por otro lado, las mejores pruebas del estudio se obtiene con en el caso de estudio CP. Al utilizar curvas de recuperación metalúrgica, los resultados varían mucho debido a que las curvas no favorecen las leyes del depósito. Finalmente, se propone para un futuro estudio, incluir información geológica en el proceso de planificación para ver como esta lo puede cambiar. Esta información puede ser, por ejemplo, dureza para relacionarlo al tiempo de residencia en el molino, o la textura de los minerales (ganga-mena, mena-mena) para relacionarlo al tamaño de liberación lo que también lleva al tiempo de residencia en el molino, etc.

ABSTRACT OF THE THESIS TO OBTAIN  
THE GRADE OF MASTER IN MINING  
ABSTRACT OF THE MEMORY TO OBTAIN  
THE GRADE OF GEOLOGIST  
BY: MARIO CLAUDIO HINOJOSA MOLINA  
DATE: 2022  
THESIS ADVISOR: NELSON MORALES VARELA

## SHORT TERM MINE PLANNING CONSIDERING GEOLOGICAL UNCERTAINTY AND OPERATIONAL RESTRICTIONS IN OPEN PIT MINING

Mine planning is a discipline of mine engineering that is responsible of generating a extraction schedule, in different time horizons, to obtain the best possible benefit for the project. In the short term open-pit mine planning, polygons of extraction are defined based on *Selective Mining Units* (SMU). These are smaller blocks that contain more information about the deposit. Generating a extraction schedule of these polygons is complex due to operational restrictions, and definition of the destination and extraction period. This problem is addressed in Nelis and Morales (2021a), but they don't take into account the uncertainty of the grades or geometallurgical variables.

In this thesis, a methodology is used that generates extraction polygons, or clusters, and the geological uncertainty of the data is taken into account through different geological scenarios. To generate the clusters, a optimization model is used whose input is parameters are the block model, size and maximum number of clusters, a search radius and economic parameters. As a result, we have a distribution of clusters, their scheduling period, destination and economic value. To study the effect of uncertainty, three types of cases and multiple tests are generated. The first is Deterministic (DET) where all scenarios use the schedule of the base case. The second is Partial Knowledge (CPAR), where each scenario has its own schedule but linked to the base case. The third is Perfect Knowledge (CP) where a schedule is generated considering that each scenario is independent. The cases of the previous studies are compared with each other and with a Block Scheduling (BS). Finally, a study is carried out using metallurgical recovery curves to study their impact on scheduling process.

The methodology is applied on a case study composed of two banks, with a total of 520 blocks and a scheduling period of 4 months. A comparison of the results of the different tests of the DET and CPAR cases is made and it is observed that in only one test there is an average economic value of DET higher than the CPAR. On the other hand, the best evidence of the study is obtained with the CP case. The results with metallurgical recovery curves vary greatly because the curves do not favor the grades of the deposit. Finally, it is proposed for a future study, to include geological information in the planning process to see how it can change it. This information can be, for example, hardness to relate it to the residence time in the mill, or the texture of the minerals (waste-ore, ore-ore) to relate it to the release size which also leads to the residence time in the mill, etc.

*A mi familia y a mi querida Susy...muchas gracias.*

# Agradecimientos

Con este trabajo le pongo fin a un largo trayecto de aprendizaje en la universidad, con altos y bajos, alegrías y penas, pero siempre saliendo adelante. En este tiempo he conocido a muchas personas que de alguna u otra forma han impactado mi vida, y en especial a ciertas personas quiero dedicarles algunas palabras.

En primer lugar, a mis padres por su apoyo incondicional, su amor, educación, valores entregados, protección, motivación y por entregarme un hogar en el que siempre me sentí seguro. Por siempre estar presente sin importar la hora o la circunstancia. A mi padre por esas horas de estudio cuando lo necesitaba, por esos días en los que íbamos a jugar a la pelota, hacer deporte los domingos a las 7 de la mañana y por todas las lecciones dadas. A mi madre por enseñarme a estudiar, a ser ordenado y por haber dejado todo por nosotros. A mi hermano por su compañía, por sus bromas y los distintos momentos vividos. Por último, pero no menos importante, a mi perrito Tony que ha sido un fiel compañero gran parte de mi vida universitaria. A todos ustedes, simplemente, muchas gracias por todo.

En segundo lugar, quisiera agradecer a Susana, el amor mi vida, mi compañera, mi todo. Ha sido un viaje maravilloso y no se como agradecerle todo lo que haz hecho por mi en estos casi 8 años de relación. También a mi suegra y suegro (Q.E.P.D.) por todo el apoyo.

Quisiera agradecer a 2 personas que son muy importantes para mi y que conozco desde que soy mechón, Marcela y Leonardo (peque y leo). Muchas gracias por todos los momentos vividos, su cariño, apoyo, por ser enormes amigos y mas aún, personas hermosas. Espero que nuestros caminos nunca se distancien y podamos seguir compartiendo como lo hemos hecho hasta ahora. También al resto de los Tratorizados y a personas que conocí tanto en geología como en minas. Por otro lado, también dar las gracias al grupo de Calidad de Vida (Valeria, Javiera, Kathy, entre otros) por su ayuda y consejos.

Agradezco a los profesores Nelson, Brian y Gonzalo por la ayuda, la confianza y el apoyo, sobretodo cuando mi suegro falleció y entendieron la posición en la que me encontraba, lo que fue muy importante para mi. También quisiera agradecer a Carol Tapia, por la ayuda durante el proceso del postgrado.

Finalmente, quisiera agradecer al Laboratorio Delphos y a sus integrantes, y al Advanced Mining Technology Center (AMTC) por el financiamiento de este trabajo a través del Proyecto Basal AFB180004.

# Tabla de Contenido

<b>1. Introducción</b>	<b>1</b>
1.1. Objetivos . . . . .	3
1.1.1. Objetivo general . . . . .	3
1.1.2. Objetivos específicos . . . . .	3
1.2. Hipótesis . . . . .	3
1.3. Alcances . . . . .	3
<b>2. Estado del arte</b>	<b>4</b>
2.1. Planificación Minera . . . . .	4
2.1.1. Valorización de Bloques . . . . .	5
2.1.2. Generación de Pit Final . . . . .	6
2.2. Incertidumbre en Planificación . . . . .	8
2.2.1. Incertidumbre Geológica . . . . .	8
2.3. Planificación en el Corto Plazo . . . . .	12
2.4. Geometalurgia . . . . .	22
2.4.1. Geología y Geometalurgia . . . . .	24
2.5. Geometalurgia y Planificación Minera . . . . .	30
2.6. Discusión . . . . .	36
<b>3. Modelo de Optimización</b>	<b>37</b>
<b>4. Metodología</b>	<b>43</b>
<b>5. Experiencias Numéricas</b>	<b>46</b>
5.1. Caso de Estudio . . . . .	46
5.1.1. Valorización . . . . .	49
5.2. Agendamiento a Nivel de Bloque . . . . .	51
5.3. Casos Determinista y Conocimiento Parcial . . . . .	53
5.3.1. Valor Económico . . . . .	56
5.3.2. Efecto número mínimo de bloques . . . . .	63
5.3.3. Saturación de destinos y secuencia de extracción . . . . .	64
5.4. Conocimiento Perfecto . . . . .	66
5.4.1. Valor Económico . . . . .	67
5.4.2. Efecto número mínimo de bloques . . . . .	69
5.4.3. Saturación de destinos . . . . .	73
5.4.4. Comparación ANB, DET, CPAR Y CP con recuperación fija . . . . .	73

5.5. Recuperación Variable . . . . .	75
5.5.1. Valor Económico . . . . .	76
5.5.2. Saturación de destinos . . . . .	78
<b>6. Análisis</b>	<b>80</b>
<b>7. Conclusiones y Trabajo Futuro</b>	<b>84</b>
<b>Bibliografía</b>	<b>86</b>
<b>Anexos</b>	<b>91</b>
<b>A. Determinista y Conocimiento Parcial</b>	<b>92</b>
<b>B. Conocimiento Perfecto</b>	<b>100</b>
<b>C. Recuperación Variable</b>	<b>105</b>

# Índice de Tablas

3.1. Descripción de parámetros, sets e índices usados . . . . .	40
5.1. Estadística básica de la ley de cobre para ambas mineralizaciones del Caso 0.	47
5.2. Parámetros económicos. . . . .	50
5.3. Pruebas realizadas para los casos deterministas y conocimiento parcial. . . . .	53
5.4. Resumen de resultados de Prueba 1. . . . .	58
5.5. Resumen de resultados de Prueba 3. . . . .	58
5.6. Resumen de resultados de Prueba 6. . . . .	59
5.7. Resumen de resultados de Prueba 7. . . . .	59
5.8. Resumen de resultados de Prueba 9. . . . .	59
5.9. Pruebas realizadas para el caso de conocimiento perfecto. . . . .	66
5.10. Resumen de resultados de Prueba 12. . . . .	67
5.11. Resumen de resultados de Prueba 13. . . . .	67
5.12. Resumen de resultados de Prueba 16. . . . .	67
5.13. Promedio de representantes usados por prueba y radio. . . . .	70
5.14. Porcentaje de uso de representantes por banco y coordenada Y. . . . .	72
5.15. Pruebas realizadas con recuperación variable. . . . .	76
5.16. Resumen de resultados de las pruebas CPAR con recuperación variable. . . . .	77
5.17. Resumen de resultados de las pruebas CP con recuperación variable. . . . .	77
A.1. Resumen de resultados de Prueba 1 y Radio 12. . . . .	95
A.2. Resumen de resultados de Prueba 2. . . . .	96
A.3. Resumen de resultados de Prueba 4. . . . .	96
A.4. Resumen de resultados de Prueba 5. . . . .	96
A.5. Resumen de resultados de Prueba 8. . . . .	97
A.6. Resumen de resultados de Prueba 10. . . . .	97
A.7. Promedio de tonelaje por destino y radio para el caso CPAR. . . . .	97
B.1. Resumen de resultados de Prueba 11. . . . .	100
B.2. Resumen de resultados de Prueba 14. . . . .	100
B.3. Resumen de resultados de Prueba 15. . . . .	100
B.4. Promedio de tonelaje por destino y radio para el caso CP. . . . .	103
C.1. Promedio de tonelaje por destino y radio para con recuperación variable. . . . .	106



# Índice de Ilustraciones

2.1. Resumen de actividades en los distintos horizontes de planificación (Ruiseco et al., 2016). . . . .	5
2.2. Secuencia de extracción Worst case (izquierda) y Best Case (derecha) (Modificado de Whittle, 2011). . . . .	8
2.3. Método tradicional o determinista versus el método estocástico (Dimitrakopoulos, 2018). . . . .	9
2.4. Pasos necesarios para realizar un agendamiento de producción estocástico con <i>simulated annealing</i> (Dimitrakopoulos, 2018). . . . .	10
2.5. Esquema explicativo del paso de los bloques de planificación a largo plazo al agendamiento en el corto plazo usando SMUs y clusters (modificado de Nelis y Morales, 2021a). . . . .	13
2.6. Distribución manual y óptima de clusters de un banco. (a) ley de corte, (b) diseño manual, (c) diseño óptimo. (Sari y Kumral, 2017). . . . .	15
2.7. Esquema de bloques problemáticos marcados con una cruz roja (Nelis y Morales, 2021c). . . . .	16
2.8. Agendamiento estocástico de corto plazo (izquierda) y determinista (derecha). (Villalba y Dimitrakopoulos, 2016). . . . .	20
2.9. Distribución manual y óptima de clusters de un banco. (a) ley de corte, (b) diseño manual, (c) diseño óptimo. (Nelis y Morales, 2021a). . . . .	21
2.10. Clasificación de las variables geometalúrgicas primarias y secundarias (o de respuesta) (Modificado de Coward et al. 2009). . . . .	23
2.11. Curva teórica máxima de recuperación-ley con texturas (izquierda) y motivo por el cual un cierto concentrado se encontraría bajo esta curva (derecha) (Cropp et al., 2013). . . . .	25
2.12. Distintas causas de una recuperación o ley de cobre menor a la esperada en un concentrado de flotación, mostrado en función al tamaño de grano para minerales de mena y ganga (Cropp et al., 2013). . . . .	26
2.13. Efecto de minerales de arcilla (ilita, caolinita, montmorillonita) en la flotación de minerales de cobre (Farrokhpay et al. 2016). . . . .	28
2.14. Curvas de recuperación en función a la ley de alimentación (Del Castillo y Dimitrakopoulos 2016). . . . .	33
2.15. Tonelaje y VPN del caso 1 (arriba) y caso 4 (abajo) (Morales et al., 2019). . . . .	35
3.1. Definición de cluster en función a un representante basado en el modelo de optimización. Los colores representan distintos clusters y su bloque representante (Modificado de Nelis y Morales, 2021a). . . . .	38

3.2.	Ejemplo de bloques representantes, candidatos no seleccionados y clusters. . .	38
3.3.	Ejemplo de arcos de precedencia entre un SMU (negro) hacia tres representantes (rojo, verde y amarillo) (izquierda) y formas de clusters generadas (derecha) (Modificado de Nelis y Morales, 2021a). . . . .	39
3.4.	Ejemplo de radios de búsqueda del modelo de optimización. . . . .	40
4.1.	Diagrama de flujo de la metodología. . . . .	45
5.1.	Distribución de las leyes de cobre oxidado (arriba) y sulfurado (abajo) del Caso 0. . . . .	46
5.2.	Distribución de las leyes de cobre sulfurado de los escenarios 8 (arriba) y 15 (abajo). . . . .	47
5.3.	Distribución de las leyes de cobre oxidado de los escenarios 8 (arriba) y 15 (abajo). . . . .	48
5.4.	Gráfico de media de ley de cobre oxidado del caso base y escenarios. . . . .	48
5.5.	Gráfico de media de ley de cobre sulfurado del caso base y escenarios. . . . .	49
5.6.	Gráfico de varianza de ley de cobre oxidado del caso base y escenarios. . . . .	49
5.7.	Gráfico de varianza de ley de cobre sulfurado del caso base y escenarios. . . . .	49
5.8.	Mejor destino por bloque del Caso Base. . . . .	50
5.9.	VPN del agendamiento a nivel de Bloque. . . . .	51
5.10.	Promedio de utilización de los distintos destinos por periodo para todos los escenarios del agendamiento a nivel de bloque. . . . .	51
5.11.	Periodo de extracción de agendamiento por bloques para dos escenarios. . . . .	52
5.12.	Ubicación bloques representantes de Prueba 2. . . . .	54
5.13.	Ubicación bloques representantes de Prueba 5 y 6. . . . .	54
5.14.	Ubicación bloques representantes de Prueba 9 y 10. . . . .	54
5.15.	Valor de conocimiento parcial (CPAR) por banco para distintas pruebas y radios. . . . .	55
5.16.	Gráfico de VPN determinista de algunas pruebas para un radio 6. . . . .	56
5.17.	Gráfico de VPN de CPAR de algunas pruebas para un radio 6. . . . .	56
5.18.	Gráfico de VPN determinista de algunas pruebas para un radio 7. . . . .	57
5.19.	Gráfico de VPN de CPAR de algunas pruebas para un radio 7. . . . .	57
5.20.	Gráfico de VPN determinista de algunas pruebas para un radio 10. . . . .	57
5.21.	Gráfico de VPN de CPAR de algunas pruebas para un radio 10. . . . .	58
5.22.	Gráfico de ley de cobre promedio por caso de la prueba 3 y radio 7. . . . .	60
5.23.	Gráfico de valor económico total por caso de la prueba 3 y radio 7. . . . .	60
5.24.	Diferencias de destino entre casos determinista y conocimiento parcial de la prueba 3 y radio 7. . . . .	61
5.25.	Destino de clusters de prueba 1, escenario 11 y R=10. . . . .	62
5.26.	Destino de clusters de prueba 3, escenario 7 y R=7. . . . .	62
5.27.	Destino de clusters de prueba 5, escenario 11 y R=6. . . . .	62
5.28.	Destino de clusters de prueba 10, escenario 7 y R=10. . . . .	63
5.29.	Gráfico de VPN de CPAR de las pruebas 5 y 6 con radio 6. . . . .	63
5.30.	Gráfico de VPN determinista de las pruebas 7 y 8 con radio 10. . . . .	64
5.31.	Gráfico de VPN determinista de las pruebas 9 y 10 con radio 7. . . . .	64
5.32.	Ocupación de planta de sulfuros para radio 6. . . . .	65
5.33.	Ocupación de planta de óxidos para radio 10. . . . .	65
5.34.	Orden de extracción de los clusters. . . . .	65

5.35. Ubicación bloques representantes de conocimiento perfecto. . . . .	66
5.36. Gráfico de VPN de conocimiento perfecto de radio 6. . . . .	68
5.37. Gráfico de VPN de conocimiento perfecto de radio 7. . . . .	68
5.38. Gráfico de VPN de conocimiento perfecto de radio 10. . . . .	68
5.39. Gráfico de VPN de conocimiento perfecto de pruebas 11 y 12 para radio 10 .	69
5.40. Gráfico de VPN de conocimiento perfecto de pruebas 13 y 14 para radio 6. .	69
5.41. Gráfico de VPN de conocimiento perfecto de pruebas 15 y 16 para radio 10.	70
5.42. Diferencia de clusters generados para las pruebas 12 (arriba) y 16 (abajo). .	71
5.43. Gráfico comparativo de VPN de distintas pruebas con radio 10. . . . .	72
5.44. Ocupación de planta de sulfuros de CP para radio 6. . . . .	73
5.45. Ocupación de planta de óxidos de CP para radio 10. . . . .	73
5.46. Gráfico de los mejores VPNs de cada caso de estudio junto con ANB. . . . .	74
5.47. Gráfico de los mejores VPNs de cada caso sin ANB. . . . .	74
5.48. Curvas de recuperación usadas. . . . .	75
5.49. Gráfico de valor económico de algunas pruebas de conocimiento parcial con recuperación variable. . . . .	78
5.50. Gráfico de valor económico de algunas pruebas de conocimiento perfecto con recuperación variable. . . . .	78
5.51. Ocupación de planta de óxidos de CP con recuperación variable. . . . .	79
5.52. Ocupación de planta de sulfuros de CP con recuperación variable. . . . .	79
6.1. Ejemplos de algunos problemas de agendamiento. . . . .	81
A.1. Ubicación bloques representantes de Prueba 1. . . . .	92
A.2. Ubicación bloques representantes de Prueba 3. . . . .	92
A.3. Ubicación bloques representantes de Prueba 4. . . . .	93
A.4. Ubicación bloques representantes de Prueba 7 y 8. . . . .	93
A.5. Gráfico de VPN determinista para un radio 6. . . . .	93
A.6. Gráfico de VPN de conocimiento parcial para un radio 6. . . . .	94
A.7. Gráfico de VPN determinista para un radio 7. . . . .	94
A.8. Gráfico de VPN de conocimiento parcial para un radio 7. . . . .	94
A.9. Gráfico de VPN determinista para un radio 10. . . . .	95
A.10. Gráfico de VPN de conocimiento parcial para un radio 10. . . . .	95
A.11. Ocupación de planta de óxidos de para radio 6. . . . .	98
A.12. Ocupación de planta de óxidos de para radio 7. . . . .	98
A.13. Ocupación de planta de sulfuro de para radio 7. . . . .	98
A.14. Ocupación de planta de sulfuro de para radio 10. . . . .	99
B.1. Gráfico de VPN de conocimiento perfecto de radio 6. . . . .	101
B.2. Gráfico de VPN de conocimiento perfecto de radio 7. . . . .	101
B.3. Gráfico de VPN de conocimiento perfecto de radio 10. . . . .	101
B.4. Gráfico de VPN de conocimiento perfecto de pruebas 11 y 12. . . . .	102
B.5. Gráfico de VPN de conocimiento perfecto de pruebas 13 y 14. . . . .	102
B.6. Gráfico de VPN de conocimiento perfecto de pruebas 15 y 16. . . . .	102
B.7. Ocupación de planta de óxidos CP de para radio 6. . . . .	103
B.8. Ocupación de planta de óxidos CP de para radio 7. . . . .	103
B.9. Ocupación de planta de sulfuro CP de para radio 7. . . . .	104
B.10. Ocupación de planta de sulfuro CP de para radio 10. . . . .	104

C.1. Gráfico de valor económico de pruebas de conocimiento parcial con recuperación variable. . . . .	105
C.2. Gráfico de valor económico de pruebas de conocimiento perfecto con recuperación variable. . . . .	106
C.3. Ocupación de planta de óxidos de CPAR con recuperación variable. . . . .	106
C.4. Ocupación de planta de sulfuros de CPAR con recuperación variable. . . . .	107



# Capítulo 1

## Introducción

Chile es un país que se caracteriza por ser minero, y dentro de esto, es uno de los países con las mayores reservas de cobre a nivel mundial (U.S.G.S., 2021). En el año 2020, se produjeron 5,733 millones de toneladas de cobre fino, lo equivalente al 27.7% de la producción mundial (Cochilco, 2021).

Dada la importancia de esta industria, no solo en Chile sino que a nivel mundial, cada etapa de esta requiere de una constante mejora en sus distintas actividades. Entre esas etapas, se encuentra planificación minera.

La planificación minera corresponde al área de ingeniería de minas que se encarga de generar un programa de explotación, en el que se determina que porción del yacimiento será explotado, cuando se extraen los recursos minerales y el mejor destino de estos (botadero, planta o stockpile). El objetivo principal de esto corresponde a la maximización del valor económico del proyecto, en términos del valor presente neto (VPN). Esto se puede hacer en distintos horizontes temporales, que son de largo, mediano y corto plazo. En este trabajo, se trata la planificación minera en el corto plazo.

El agendamiento en el corto plazo, cuyo horizonte temporal no supera 1 año, se encarga de cumplir con los objetivos del agendamiento de largo plazo. En esta etapa se tiene un mayor conocimiento del depósito dado que se tiene información de los pozos de tronadura. El inconveniente es que se generan bloques de menor tamaño llamados *Selective Mining Units* (SMU), que debido a su tamaño generan un inconveniente operacional y es necesario agruparlos en clusters que son un conjunto de bloques que comparten el mismo destino. Pero si bien, en el corto plazo, se tiene un mayor nivel de información, esta es parcial lo que genera que se inserte *incertidumbre* en el proceso que no siempre se considera.

La incertidumbre se da porque se tiene un conocimiento incompleto de algo, y en el caso de la minería, se diagnostican 3 fuentes principales: mercado, operacional y geológica. La primera está relacionada a la variación de los precios de los metales de interés, costos operacionales y al comportamiento del mercado a nivel mundial (factores que son difíciles de predecir). El segundo, está relacionado a la disponibilidad técnica y rendimiento de los equipos. En este trabajo se trata más en detalle la tercera fuente, la geológica.

La incertidumbre geológica se da porque se tiene un muestreo sesgado del depósito a través de los sondajes, es decir, falta de información geológica. Solo mediante un muestro exhaustivo se podría reducir su efecto, pero se requiere de una gran inversión económica debido a su alto valor (Erickson y Padgett, 2011). Para considerar este tipo de incertidumbre en el proceso de planificación, se utilizan simulaciones (se generan cierta cantidad de escenarios equiprobables). Gracias a los avances en la investigación, se ha logrado incluir estos escenarios en la optimización matemática estocástica en donde los modelos se resuelven bajo distintos enfoques (como los heurísticos, metaheurísticos, SIP) para poder estudiar las diferencias entre tener una plan minero que se genera mediante un escenario de estimación (determinista) frente a los escenarios equiprobables (estocástico). Aquí se estudia la variación en VPN, utilización de la planta, factibilidad de llevar a cabo el plan minero, etc.

Actualmente, la minería se concentra en la explotación de depósitos que se encuentran en mayores profundidades dado que los yacimientos superficiales se han ido agotando con el tiempo, lo que se traduce en menores leyes y complicaciones en su procesamiento. En estos se encuentran distintos minerales de cobre (primarios y secundarios) como también distintos minerales ganga. Entre estos últimos se pueden encontrar arcillas o filosilicatos (biotita, moscovita, etc.) que generan inconvenientes en los distintos procesos, ya sea porque hacen que se consuma una mayor cantidad de energía en la molienda o porque generan problemas en la flotación. Es por este motivo que surge la importancia de la geometalurgia, cuyo fin es encontrar los distintos impactos que tiene la geología del depósito en el procesamiento a través de ensayos a escala de laboratorio con distintas muestras obtenidas in-situ. En estudios recientes, se ha incluido información geometalúrgica en planificación minera de largo plazo mostrando resultados positivos.

El inconveniente que presentan las variables geometalúrgicas es que no son aditivas, lo que las hace complejas. Al mezclar distintos bloques su recuperación o su comportamiento en la planta no es el mismo al que sería si se procesarán de manera individual. Esto no suele ser tomado en consideración dada la complejidad de poder describir de una forma adecuada este comportamiento en la planta. Por otro lado, al no tener en cuenta información geometalúrgica se puede variar de forma importante el beneficio económico de un proyecto minero.

Dado este escenario, en esta tesis se trata la planificación minera en el corto plazo, pero considerando incertidumbre geológica de los datos. En Nelis y Morales (2021a) se propone una metodología que genera clusters para un agendamiento de corto plazo, pero no consideran la incertidumbre de los datos en el proceso. Por otro lado, se considerará una curva de recuperación metalúrgica para estudiar el efecto de tener distintas recuperaciones dada una ley de alimentación.

## 1.1. Objetivos

### 1.1.1. Objetivo general

El objetivo principal de la tesis consiste en estudiar el efecto de tener distintos escenarios geológicos en el agendamiento operacional de corto plazo en minería a cielo abierto considerando la generación de clusters mediante el uso de bloques representantes.

### 1.1.2. Objetivos específicos

Los objetivos específicos con los que se espera cumplir el objetivo general son los siguientes:

- Analizar el impacto de variar la ubicación y cantidad de bloques representantes.
- Evaluar los distintos planes mineros considerando distinto nivel de información.
- Cuantificar el impacto de emplear curvas de recuperación metalúrgicas.

## 1.2. Hipótesis

Empleando distinta cantidad de representantes y su ubicación en el espacio, se puede modificar y mejorar los resultados obtenidos en comparación a si se considera una ubicación fija.

## 1.3. Alcances

Los alcances que tuvo el trabajo se definen con la intención de evitar malos entendidos y de aclarar de antemano las limitantes que estuvieron presentes:

- El horizonte de trabajo considerado es de corto plazo, máximo 4 meses.
- Para la generación de los escenarios geológicos, no se desarrolla una nueva técnica de simulación.
- Parámetros económicos como precio del metal de interés y costos (mina, procesamiento y venta), se consideran fijos.
- Para la utilización de recuperación variable, se utilizan curvas de recuperación metalúrgica. No se genera un modelo de variables geometalúrgicas.



# Capítulo 2

## Estado del arte

En esta sección se presenta la revisión bibliográfica realizada de la tesis. Esta sección se divide en planificación minera, incertidumbre en planificación, planificación de corto plazo, geometalurgia, y finalmente geometalurgia y planificación minera.

### 2.1. Planificación Minera

Planificación minera corresponde al área de ingeniería de minas que se encarga de generar un programa de explotación, en el que se determina que porción del yacimiento será explotado, cuando se extraen los recursos minerales y el mejor destino de estos (botadero, planta o stock pile). El objetivo principal de esto corresponde a la maximización del valor económico del proyecto, en términos del valor presente neto (VPN). Por otro lado, el plan minero debe cumplir con otras restricciones como políticas, medioambientales, geológicas, ser factibles operacionalmente, etc. (Tabesh y Askari-Nasab, 2011; Osanloo et al., 2008).

La planificación minera se puede realizar en distintos horizontes temporales, siendo de corto, mediano y largo plazo. En la Figura 2.1 se aprecia un resumen de las características fundamentales de cada uno de los horizontes de planificación. La descripción de cada uno de estos horizontes se puede ver a continuación (Ruiseco et al., 2016; Sari y Kumral, 2017; Osanloo et al., 2008).

- Planificación de largo plazo (Estratégico): En el agendamiento de largo plazo se genera una imagen general del proyecto. Se basan en modelos de bloques donde cada uno de estos bloques se genera mediante simulación o estimación de información limitada obtenida a través de sondajes de exploración. Ayuda a entender si el proyecto es viable o no, como evolucionará a lo largo del tiempo, y que sensibilidades macroeconómicas lo pueden afectar. Se dedican a realizar los planes estratégicos y de negocio. Se define la vida de la mina, las reservas, cuando se realizan las inversiones, el mejor destino de los bloques, cuanto se va a procesar y las capacidades de procesamiento. Se cuantifican los recursos humanos y equipos a utilizar. Su función es maximizar el VPN. El nivel de precisión es de fase-banco y el de información disponible es bajo.
- Planificación de mediano plazo (Táctico): Su objetivo es asegurar el cumplimiento del

plan de largo plazo mediante distintos objetivos (que pueden estar relacionados a mercado, producción o mantenimiento) e información más detallada. En este tipo de planificación, se aborda la planificación de los procesos de perforación, tronadura y carguío. Se da más información de las fases, considerando polígonos. Su horizonte temporal es de 1 a 5 años.

- Planificación de corto plazo (Operacional): Cuando comienza la explotación de bancos, a través de los pozos de tronadura se puede obtener información más precisa (es decir, se trabaja con un nivel de información elevado) sobre la ley del banco. Con esto, se pueden generar bloques más pequeños llamados SMU (*Selective Mining Units*) que permiten generar una planificación más precisa. También se encarga de las tasas de producción, requerimientos de calidad, utilización de equipos, y recuperación y rendimiento del procesamiento de minerales. Su horizonte temporal no pasa de 1 año, pueden ser de días, semanales o mensuales. En la sección 2.3, se comenta más en detalle sobre la planificación de corto plazo.

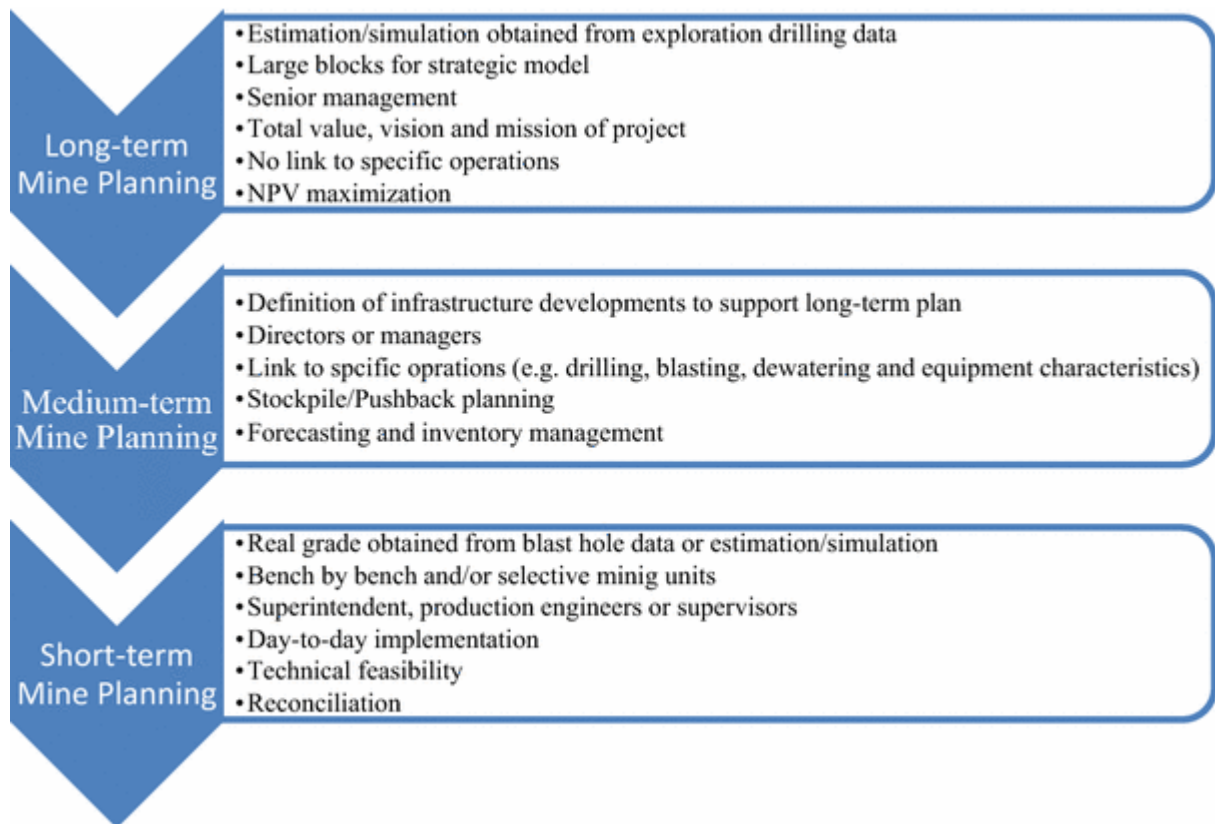


Figura 2.1: Resumen de actividades en los distintos horizontes de planificación (Ruiseco et al., 2016).

### 2.1.1. Valorización de Bloques

Para llevar a cabo este proceso, se hace uso de un modelo 3D de bloques que corresponde a una representación del depósito cuya información se consigue mediante sondajes de campaña de exploración. Cada uno de estos bloques contiene distintos tipos de información, como densidad, ley de elemento(s) de interés, litología, alteración, minerales (económicamente im-

portantes y contaminantes), etc. Los modelos de bloques se generan mediante técnicas de geoestadística, como estimación (kriging) o simulación, de los datos disponibles.

Para la valorización de los bloques, también se requiere información relativa a los costos mina, de procesamiento y de venta (que también incluye costos de transporte y refinación), y precios del elemento que se procesa. Una vez se tiene esta información, se pueden valorizar los bloques que componen el modelo mediante las siguientes ecuaciones (Yarmuch, 2021).

$$V_{BP} = T \cdot L \cdot f \cdot R \cdot (P \cdot RF - C_V) - T \cdot (C_M + C_P) \quad (2.1)$$

$$V_{BB} = -T \cdot C_M \quad (2.2)$$

Donde

- $V_{BP}$ : Beneficio obtenido al mandar el bloque a proceso.
- $V_{BB}$ : Beneficio obtenido al mandar el bloque a botadero.
- $T$ : Tonelaje del bloque.
- $L$ : Ley del elemento de interés.
- $f$ : Factor de conversión en caso de ser necesario (por ejemplo, en caso de cobre, sería 2,204.62 [lb/ton]).
- $P$ : Precio del elemento de interés.
- $RF$ : Revenue factor.
- $C_V$ : Costo de venta, refinación y transporte del elemento de interés.
- $C_M$ : Costo mina del bloque.
- $C_P$ : Costo de procesamiento del bloque.

En la Ecuación 2.1 se considera solo un elemento de interés, pero pueden ser más en caso de tener un yacimiento polimetálico. El valor final del bloque corresponde al que aporte el mayor beneficio entre las ecuaciones 2.1 y 2.2. Puede existir más de un destino posible (por ejemplo, distintas plantas de procesamiento), y en tal situación se escoge el que aporte el mayor beneficio. Una vez valorizado los bloques, se procede a calcular los pits.

### 2.1.2. Generación de Pit Final

El cálculo del pit final contempla el uso de la información adquirida al valorizar los bloques, información geotécnica para conocer él(los) ángulo(s) de talud máximo, el ritmo de explotación de mina y de procesamiento, y una tasa de descuento. El pit final contempla todos los bloques que pertenecen a una envolvente económica que maximiza la rentabilidad del negocio minero. Para resolver esto, el algoritmo basado en la teoría de grafos de Lerchs

y Grossmann (1965) genera un método computacionalmente tratable y exacto (generando una solución óptima) que permite determinar el subconjunto de bloques del yacimiento que maximiza el valor no descontado. Otro método es el del cono flotante (Laurich y Kennedy, 1990) que asume un bloque como punto de referencia desde donde expandir el pit hacia arriba sujeto a las precedencias de cada bloque. Pero sus inconvenientes son que el diseño del pit final está sujeto a la secuencia en la que los bloques de referencia son escogidos y que muchos bloques de referencia sean necesarios para obtener un diseño de pit razonable, pero no necesariamente óptimo (Newman et al., 2010).

Para conocer los límites del pit final, se generan una serie de pits anidados variando el precio del elemento de interés. En la Ecuación 2.1, el precio del metal de interés está multiplicado por el revenue factor (RF). Cuando el RF toma el valor 1, se tiene un pit considerando el precio inicial, pero a medida que el RF disminuye, se obtienen pits cada vez más pequeños en los que solo van quedando áreas de alta ley y/o menor cantidad de estéril (Hustrulid et al., 2013). El primer pit rentable, es por donde debería de comenzar la explotación del depósito y a medida que los pits aumentan en tamaño (debido al aumento del RF), se marca una secuencia de explotación, que al mismo tiempo sirve para definir las fases.

Entre las distintas metodologías propuestas para la extracción del material, existen 2 denominadas best case y worst case (Figura 2.2) (Whittle, 2011).

- *Best case*: Representa una secuencia de extracción de pit a pit, en la que la parte de extracción de estéril no se hace completamente al inicio, adelantando el acceso al mineral. Esta secuencia es más compleja que el worst case, pero obtiene un VPN mejor dado que comienza a extraer mineral rápidamente. Sin embargo, esta metodología no considera los anchos operacionales mínimos que deben existir, por lo que, operacionalmente es difícil de llevar a cabo, presentando problemas de espacio para desarrollar las distintas labores, entre otros.
- *Worst case*: Representa una secuencia de extracción de banco a banco, que es sencilla de llevar a cabo, con un excelente acceso a la mina y baja complejidad. No obstante, la cantidad de estéril que se remueve en los primeros años de explotación es muy alta, que luego disminuye en el tiempo. Por consiguiente, muchos de los costos se llevan a cabo en los primeros años de operación, mientras que el acceso y explotación del mineral se retrasa, lo que lleva a un VPN bajo.

Para la selección del pit final se toma como referencia el valor de cada pit generado, la cantidad de reservas, diferencia entre los casos antes descritos, etc. También se puede tomar como opción el análisis de la relación de estéril mineral (REM) de cada pit, y evaluar el impacto que tiene eso en el medio ambiente. Posteriormente a esta etapa se generan las fases o push backs, que son un conjunto de pits cuya planificación es más manejable. Al momento de generar las fases es necesario asegurarse de que existirá un suministro de mineral adecuado, de que existan anchos mínimos para realizar labores de extracción de los equipos de carguío y transporte, etc. Este es un proceso iterativo, donde a través de distintas cantidades de fases o de dimensiones, se busca obtener el mejor plan minero, es decir, el que aporte el mayor VPN posible (sujeto a las restricciones operacionales y de la empresa). Una vez culminada esta etapa, se pasa al diseño minero.




Figura 2.2: Secuencia de extracción Worst case (izquierda) y Best Case (derecha) (Modificado de Whittle, 2011).

## 2.2. Incertidumbre en Planificación

En la metodología tradicional, que consta de un enfoque determinístico, se utilizan varios parámetros que se consideran fijos pero que en realidad fluctúan en el tiempo, por ejemplo, el precio del metal de interés, modelo geológico, costos, entre otros. El inconveniente con este proceso es que se tiene un conocimiento incompleto, y esto genera incertidumbre que puede aumentar el riesgo de un proyecto generando planes poco realistas.

Dimitrakopoulos (1998) clasifica la incertidumbre, según su fuente, como geológica (relacionada a la variación in-situ de las leyes, tipo de material, estructuras, etc.), técnica (como capacidad de excavación, operacionales, disponibilidad de equipos, etc.) y económica (precios de los metales de interés, costos de capital, costos operacionales, etc.).

En la siguiente sección, se comenta la incertidumbre geológica y diferentes formas en las que se ha incluido en el proceso de planificación minera.

### 2.2.1. Incertidumbre Geológica

La incertidumbre geológica se genera porque se tiene un conocimiento limitado del yacimiento a través de sondajes separados cada cierta distancia, generado a partir de un muestreo finito. Al utilizar técnicas de estimación, como kriging, se genera un suavizamiento de los datos que no representan la variabilidad real de estos. En otras palabras, se suele sobrestimar los valores bajos y subestimar los altos. Por ende, al momento de llevar a cabo el proceso de planificación, se utiliza información que no es real.

La incertidumbre geológica es una de las mayores fuentes de incertidumbre que contribuye a no alcanzar las expectativas de un proyecto. Vallee (2000), comenta que en los primeros años de producción aproximadamente un 60 % de operaciones mineras han tenido una tasa de producción 70 % menor a lo diseñado.

Es por este motivo que se emplean otras técnicas, como la simulación condicional. El objetivo es cuantificar la incertidumbre geológica mediante la generación de distintos modelos equiprobables y como su nombre dice, son condicionales a los datos originales y a sus características estadísticas. Con esto se logra incluir en el proceso la incertidumbre geológica, para así manejar y controlar el riesgo, logrando mejores resultados en el negocio minero. En

la Figura 2.3 se puede observar lo antes mencionado. A continuación, se comentan algunos estudios que incluyen simulación en el proceso de planificación.

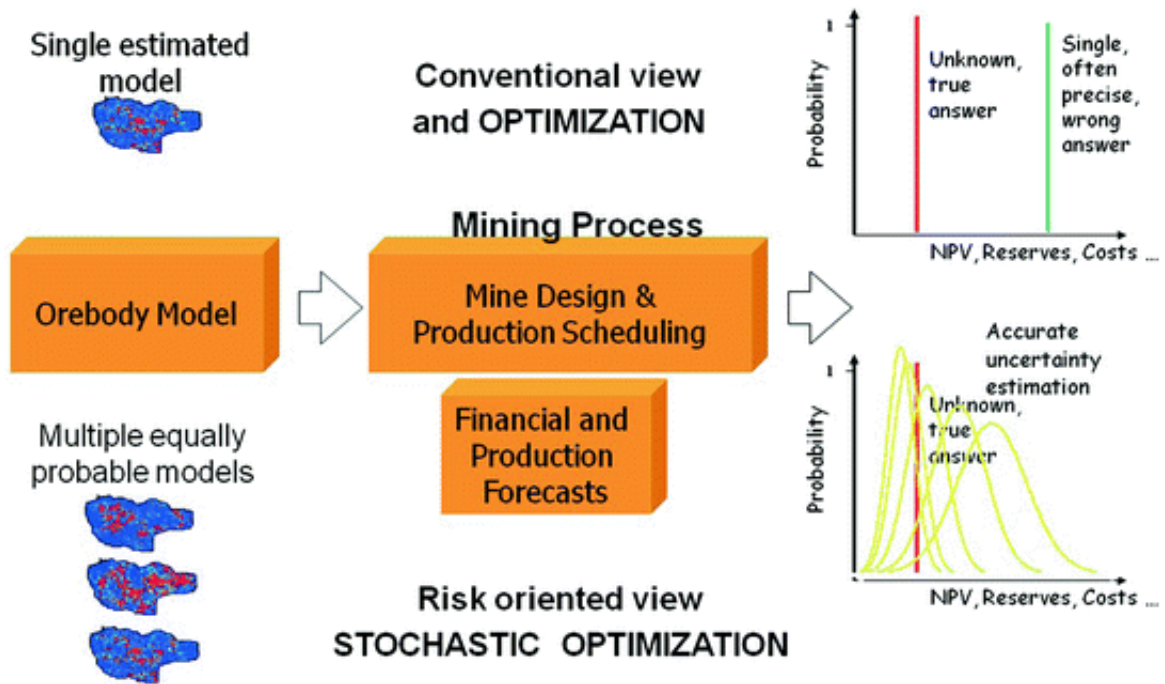


Figura 2.3: Método tradicional o determinista versus el método estocástico (Dimitrakopoulos, 2018).

En Dimitrakopoulos et al. (2002) los autores comentan sobre la importancia de incluir la incertidumbre geológica en el proceso de planificación minera. Indican que se puede cuantificar la incertidumbre al generar múltiples realizaciones de los datos, mediante simulación condicional, pero su mayor desventaja es que es un proceso largo y no es sencillo de realizar. Propone dos nuevas metodologías más rápidas. La primera corresponde a secuencia generalizada de simulación gaussiana (GSGS) y simulación de bloques directos (que es más rápido y requiere de menos uso de memoria que el anterior). En un ejemplo, muestra la diferencia en resultado generado entre un modelo estimado (kriging ordinario) y simulado (mediante 50 realizaciones) con el objetivo de resaltar las diferencias entre las proyecciones financieras y de procesamiento que se pueden obtener. Lo primero que se observa, es que el VPN proyectado por el kriging tiene una probabilidad de 2-4% de ocurrencia y que el VPN posible a obtener del proyecto es un 25% menor. Por otro lado, al considerar la incertidumbre, se aprecia que el costo de procesamiento obtenido por el kriging puede estar subestimado y que las leyes de alimentación al molino muestran una alta variabilidad. Con esto, el autor muestra la importancia de considerar la incertidumbre geológica porque permite una mejor toma de decisión, pero, por otro lado, no se menciona nada en lo que respecta a planificación minera.

Dimitrakopoulos (2011) aplica una simulación secuencial para generar una optimización estocástica, que además considera dos enfoques. El primero está basado en *Simulated Annealing* (SA) (Figura 2.4), que es un método de optimización heurística, cuyo objetivo es encontrar al agendamiento para ciertos bloques que no tienen el mismo periodo de producción con el fin de minimizar la desviación en lo que respecta al objetivo de producción. Para

llevar a cabo este proceso, es necesario realizar una secuencia de extracción para cada una de las simulaciones, y luego, se emplea el SA. El otro consiste en el *Stochastic Integer Programming* (SIP) que considera incertidumbre al momento de realizar agendamiento mediante modelos equiprobablemente simulados y que entrega una producción óptima que corresponde al agendamiento que arroja el máximo valor total descontado. Este modelo permite la gestión del riesgo geológico en términos de no cumplir los objetivos previstos durante la operación real. En el caso de estudio empleado en el artículo, se obtiene un aumento del VPN de un 25 % considerando el SIP o el SA. Por otro lado, los límites del pit estocásticamente óptimos aumentaron en un 15 % en comparación con métodos tradicionales (determinísticos), lo que se traduce en más tonelaje, en mayor vida útil de la mina y en un aumento aproximado del 10 % en el VPN.

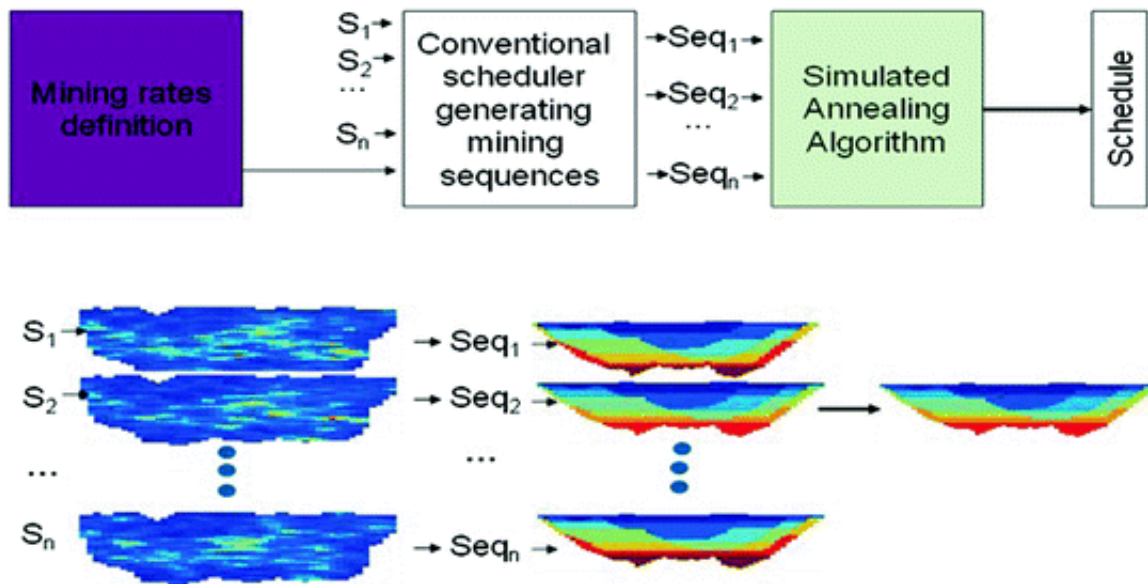


Figura 2.4: Pasos necesarios para realizar un agendamiento de producción estocástico con *simulated annealing* (Dimitrakopoulos, 2018).

El *simulated annealing* lo aplica Leite y Dimitrakopoulos (2007) en un depósito de cobre diseminado de baja ley, entregando como resultado que la producción convencional (que usa un modelo estimado mediante kriging) tiene una alta probabilidad de no cumplir con las expectativas de producción dado que sobreestima los datos y, sobreestima el tonelaje para bajas leyes de corte y lo subestima para bajas leyes de corte. Con respecto al VPN, se obtiene más de un 26.2 % con el agendamiento estocástico que con el convencional.

Albor C. y Dimitrakopoulos (2009) comparan el agendamiento con la metodología tradicional (estimación mediante kriging) con una metodología que considera la incertidumbre geológica. Los resultados indican que los objetivos de producción no podrían cumplirse y que el VPN se subestima al considerar el método tradicional. Por otro lado, también realizan un análisis de sensibilidad del método de *simulated annealing*, para analizar sus componentes críticas, en lo que respecta al número de secuencias mineras necesarias, del “congelamiento” de bloques que tiene un 100 % de probabilidad de estar siempre en el mismo periodo de extracción, la extensión de los límites del pit, etc. para lo que determinaron que para el caso de estudio solo diez simulaciones eran suficientes y que el porcentaje de bloques congelados

solo afecta el tiempo que demora el programa, entre otros.

Leite y Dimitrakopoulos (2014) utilizan el SIP en el que la función objetivo se divide en dos partes. La primera tiene como objetivo maximizar el VPN mientras que la segunda minimiza las desviaciones y distribuye el riesgo entre los periodos de la vida de la mina mediante la tasa de descuento geológica (GRD). Este término fue introducido en Dimitrakopoulos y Ramazan (2004), y quiere decir que, si se utiliza un GRD alto, las áreas de menor riesgo (en términos de alcanzar objetivos de producción) serán extraídas antes, pero si el GRD es bajo el riesgo se distribuye en una tasa más balanceada entre los periodos de producción. En el caso de estudio, se obtiene como resultado que solo en dos años se alcanza la producción predicha, el VPN obtenido mediante SIP es en promedio un 29 % mayor y que la vida útil de la mina es un año menos para el SIP. Esto se relaciona a que el método convencional (kriging) sobreestima la cantidad de mineral (como ya se mencionó anteriormente).

El *simulated annealing* tiene la ventaja de que entrega un resultado rápido, pero su desventaja es que no entrega un resultado óptimo. Además, como se menciona anteriormente, aparte de generar las distintas simulaciones, es necesario generar planes de producción para obtener una secuencia de extracción, y este es el input del *annealing*. Con respecto al SIP, esta entrega un resultado óptimo y no es necesario definir una secuencia de extracción. Por otro lado, en ninguno de esos trabajos se considera la información a corto plazo (es decir, la que se puede obtener durante el funcionamiento mismo de la mina, por ejemplo, en las perforaciones de tronadura). Nelis y Morales (2017), implementan información de corto plazo mediante un programa estocástico de dos etapas y se observa que mientras antes se tenga la información se obtienen mejores beneficios y mayor cantidad de metal (pero su impacto no es tan significativo).

Posteriormente, en Nelis et al. (2018) comparan el rendimiento de dos modelos de planificación de minas estocásticas neutrales en el riesgo. El primer modelo se basa en la minimización de las desviaciones con respecto a un objetivo de producción. Su función objetivo consta en una primera parte que maximiza el VPN mientras que la segunda parte considera costos de desviación, (que utiliza el riesgo geológico como un factor de descuento). El segundo modelo, que es el de las dos etapas estocásticas, en su función objetivo el primer término representa el costo de extracción mientras que el segundo representa el beneficio esperado obtenido para las decisiones de procesamiento teniendo en cuenta cada escenario geológico. En el caso de estudio, se comparan los dos modelos del trabajo y el modelo determinístico en un depósito del tipo pórfido de cobre. Ambos modelos estocásticos muestran mayor VPN y tonelaje en comparación al determinístico. El modelo de desviación presenta más bloques extraídos en comparación al modelo de dos etapas, esto dado a que el primero apunta a extraer más tonelaje para minimizar el costo de desviación (por incumplimiento del objetivo de producción), mientras que el segundo modelo explota menos, pero con valor similar porque su función objetivo maximiza el VPN. También se observa que, con el modelo de desviación, se extraen más bloques antes y eso viene dado por que considerando la tasa de descuento la función de beneficio, procesar un bloque antes es más beneficioso que hacerlo después.

Se puede observar que ninguno de los trabajos antes mencionados utiliza variables geológicas o geometalúrgicas en su completitud. Ignorar este tipo de información al momento de realizar planificación minera, puede generar problemas en la cadena de valor debido a que



puede afectar los requerimientos energéticos en el proceso de chancado o molienda (debido a distintos índices de chancabilidad o moliendabilidad), a la flotación (distintos tipos de textura), rendimiento, entre otros (Dowd et al. (2016); Kumar y Dimitrakopoulos (2019)). De este tipo de variables trata la sección 2.4.

## 2.3. Planificación en el Corto Plazo

La planificación minera de corto plazo presenta diversos desafíos para poder cumplir con el agendamiento de largo plazo. Uno de estos corresponde al agendamiento de las unidades mineras en el corto plazo con el fin de poder alcanzar el objetivo de producción y los ingresos estimados. Como se menciona en la sección 2.1, en el corto plazo se tiene un nivel de información elevado debido a que se estudia el material de los pozos de tronadura con lo que se tiene una mejor noción de las leyes y tipo de mineralogía del depósito. Por lo general el espaciamiento entre pozos de tronadura es menor al tamaño de bloque empleado en planificación a largo plazo y por ello esos bloques se subdividen en *Selective Mining Units* (SMU por sus siglas en inglés) que son bloques de menor tamaño con lo que se tiene una mejor distribución de la ley, contaminantes, información geológica, etc. que puede utilizar el planificador para poder definir el mejor destino posible.

Debido al tamaño de los SMUs surge una restricción operacional impuesta por la selectividad de los equipos de carguío y transporte, y el espacio de tronadura debido a que estos son mayores a las dimensiones de los SMUs. Es por esto que no se puede trabajar a un nivel de SMU, aunque se tenga un mejor conocimiento, motivo por el cual se generan los clusters (*mining cuts*), que consiste en agrupar distintos SMU (para lo que se requiere la experiencia del planificador y que también apunta a que sean factibles de una forma operacional), que se explotan en el mismo periodo y son enviados al mismo destino (aunque el destino de algunos SMUs cambie al generar los clusters) (Nelis y Morales, 2021a). En la Figura 2.5 se puede ver una representación de lo explicado, en donde se tiene en primer lugar bloques de agendamiento de largo plazo, luego se generan SMUs utilizando la información de pozos de tronadura, para luego definir los clusters, su destino y su agendamiento.

El proceso para generar los clusters es bastante demandante en tiempo que por lo general consiste en un trabajo de prueba y error porque puede ser que hayan clusters que sean infactibles en términos de alcanzar los objetivos de producción. Por otra parte, manualmente se realiza otro paso para suavizar el contorno de los clusters para facilitar el trabajo de los equipos de carguío y transporte.

A continuación, se comentan distintos trabajos en los que se ha tratado la formación de clusters y agendamiento de corto plazo. En algunos se comenta principalmente la parte de generar polígonos de extracción o de delimitación de zonas de mineral-estéril, mientras que en otros se comentan distintos modelos de agendamiento de corto plazo.

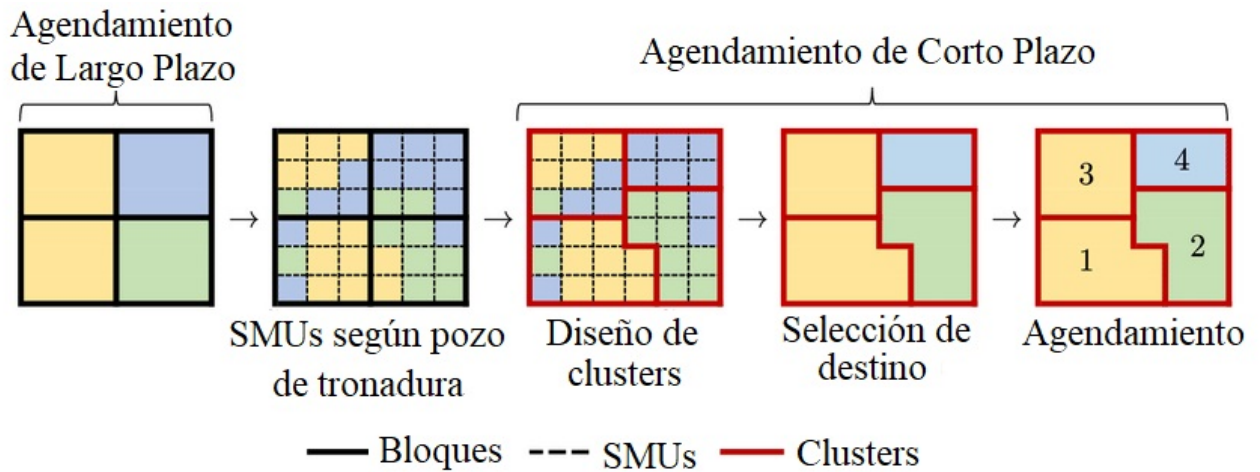


Figura 2.5: Esquema explicativo del paso de los bloques de planificación a largo plazo al agendamiento en el corto plazo usando SMUs y clusters (modificado de Nelis y Morales, 2021a).

En Norrena et al. (2001) se propone un modelo de optimización con el objetivo de generar polígonos que separen el material mineral y estéril en un banco. Su modelo consiste en determinar límites entre mineral y estéril prácticos de tal forma de minimizar la cantidad de estéril enviada a planta y la cantidad de mineral enviada a botadero. Para ello, se generan distintos polígonos iniciales para los que el modelo ira modificando sus vértices (trasladándolo, uniendo vértices muy cercanos, agregando vértices si dos vértices están muy separados, etc.) con el objetivo de maximizar el valor económico y la facilidad de extracción (en el estudio los autores lo denominan *diggability*). En relación con lo último, un polígono sin bordes agudos tendría un *diggability* elevado, mientras que un polígono tortuoso de explotar presenta un *diggability* bajo, por lo que, dicho valor depende tanto de la geometría del polígono como del equipo de carguío. Por otro lado, este valor se aplica como una penalización en la función objetivo. Para resolver dicho inconveniente, el modelo usa *simulated annealing*. El modelo se compara con distintos polígonos generados de forma manual en el que los resultados fueron similares pero el resultado del modelo genero mejor valor económico y menores penalizaciones. En este estudio no se genera un agendamiento.

En Norrena et al. (2002) los autores trabajan con el mismo modelo antes descrito, pero agregan la posibilidad de utilizar polígonos anidados. Esto considera poder generar polígonos de lastre dentro de un polígono de mineral, y viceversa. Por otro lado, también proponen usar una conversión de ley a beneficio que cuantifica la incertidumbre. Para finalizar, aplican el algoritmo a un caso de estudio. A diferencia de Norrena et al. (2001) y Norrena et al. (2002), en Neufeld et al. (2003) aplican el mismo modelo de optimización, pero esta vez a un depósito polimetálico de níquel y cobre.

Kumral (2015) propone una metodología de toma de decisiones sobre donde enviar SMUs de tal forma de minimizar las pérdidas asociadas a una mala clasificación. La función objetivo busca minimizar los costos y se basa en la función de Taguchi de pérdida de calidad en donde dicha pérdida se calcula como la diferencia cuadrática entre la calidad de un producto (en este caso ley de un bloque) y el valor objetivo. Por lo general, se suele tener una información sesgada del depósito (debido a que el modelo de bloques se genera mediante información

geológica limitada) por lo que definir los destinos de los bloques en función a una política de ley de corte puede generar una mala clasificación. Por ende, el autor propone utilizar leyes objetivo para cada destino y a dicho valor restarle la ley de cada SMU (promedio de ley de bloques que la componen) y así determinar su mejor destino. El caso de estudio consiste en un depósito de oro y plata, del que se cuenta con un total de 3,600 SMUs (un banco), que se pueden repartir en un total de cinco destinos. De dicho banco se cuenta con diez simulaciones. El modelo propuesto se compara con otros dos enfoques, uno de minimización de pérdidas y otro de maximización de beneficio. En los otros dos enfoques, se genera una violación de la capacidad de procesamiento. En lo que respecta al beneficio, la metodología propuesta genera 2.8% más que el enfoque de maximización de beneficio y 6.4% más que el de minimización de pérdidas. No se menciona el detalle de como hacen el agendamiento.

En Ruiseco et al. (2016) se presenta un modelo de optimización basado en un algoritmo genético, cuya función objetivo consiste en maximizar el valor bajo la restricción que los SMUs que caigan dentro de un cierto radio de búsqueda sean enviados al mismo destino. Dicho radio de búsqueda está relacionado a un cierto espacio operacional. El modelo genera distintas soluciones (*fitness*) que corresponden al valor de un cluster con ciertos límites (*dig-limits*) factibles menos un parámetro de desviación (*diggability*). Para encontrar la mejor solución posible, va mutando los distintos *fitness*, tomando distintos parámetros de diferentes soluciones. El resultado obtenido con el modelo de optimización se comparó con un resultado generado de forma manual donde se aprecia que el último se enfoca principalmente en la clasificación de los SMUs (de hecho, envía más SMUs a su mejor destino) pero el modelo de optimización genera un mejor beneficio y *fitness* y creando mejores límites.

Sari y Kumral (2017) proponen resolver el problema de *dig-limit* a través de un MILP (*Mixed Integer Linear Programming*). Los autores generan *frames*, en donde cada SMU que se encuentre dentro de él debe tener idéntica identificación (ya sea mineral o estéril). Los *frames*, que pueden tener forma rectangular o cuadrada, están hechos en función a la distancia máxima que puede alcanzar una excavadora (equipo de carguío) localizada en el centro de un círculo. Un *frame* se considera válido si todos los SMUs que la componen son lastre o mineral y cada SMU debe estar asignado por lo menos a un *frame* válido. El objetivo del modelo de optimización es maximizar los ingresos en un banco sujeto a limitantes de los equipos. Este modelo se aplica a un caso de estudio de distintos bancos de una mina de oro, donde se aprecia que genera una clara separación entre lastre y mineral. A modo de comparación, se genera un diseño de clusters de forma manual, y si bien los resultados eran similares en términos de límites de los clusters, el modelo de optimización logro obtener un 6.5% más de valor económico. Esta distribución de clusters se puede observar en la Figura 2.6. Uno de sus inconvenientes es el tiempo de ejecución del modelo y que no considera la capacidad mina o de planta en el proceso.

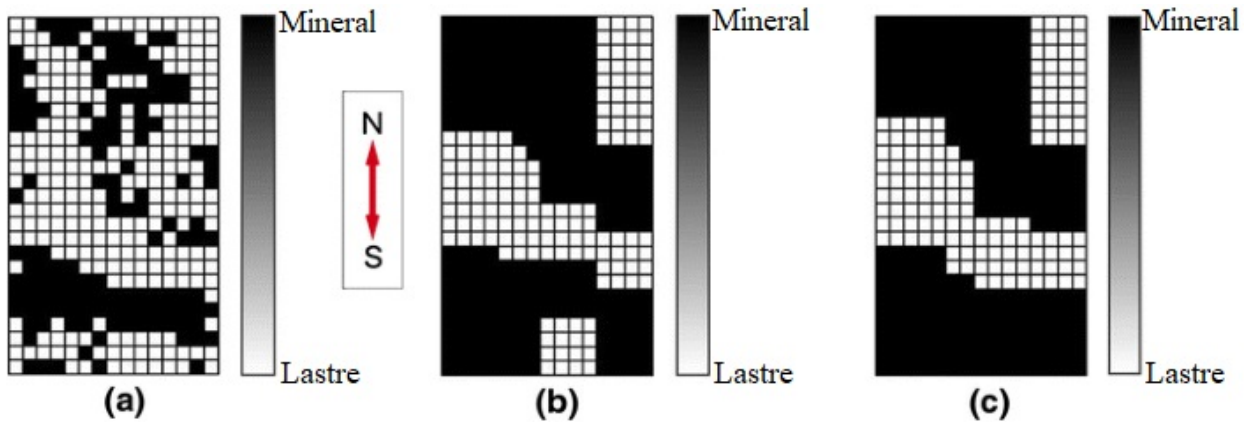


Figura 2.6: Distribución manual y óptima de clusters de un banco. (a) ley de corte, (b) diseño manual, (c) diseño óptimo. (Sari y Kumral, 2017).

Tabesh y Askari-Nasab (2011) implementan un modelo de optimización que genera clusters mediante la agregación de bloques para planificación minera. El algoritmo agrega bloques a un cluster mediante un índice de similitud que se define en función a la ley, tipo de roca, distancia y forma de cluster inferiores (se pueden agregar más, pero esto aumentaría su complejidad). Este índice se calcula, para los bloques de cada banco, considerando un parámetro de distancia euclidiana normalizada de la ubicación de dos bloques y de sus leyes. Por otro lado, también considera penalización en caso de que dos bloques tengan distintos tipos de roca y por la ubicación de dos bloques que no estén sobre el mismo cluster ubicado justo en el banco inferior. El algoritmo está basado en un enfoque jerárquico y consiste en dos etapas. La primera parte consiste en un enfoque aglomerativo, lo que significa, que forma clusters por banco desde el fondo hacia arriba (superficie) en función al índice de similitud. El modelo tiene como input un número máximo de bloques que pueden componer un cluster. Por otro lado, en la segunda parte se emplea un procedimiento de *Tabu Search* que busca reducir el número de arcos de precedencia entre clusters de distintos bancos mediante la modificación de los clusters. El algoritmo es empleado en un depósito de hierro y los resultados indican que la forma y tamaño de los clusters pueden impactar el VPN en un 10-15 %.

El algoritmo antes mencionado es usado por los mismos autores en Tabesh y Askari-Nasab (2013) donde se emplea usando distintos criterios en el índice de similitud. Estos criterios, con los que se busca generar clusters homogéneos, son de tamaño (que no sean clusters ni muy grandes ni muy pequeños), tipo de roca (relación de los distintos tipos de roca dentro de un mismo cluster), dilución con respecto al destino (relación de los distintos destinos a nivel de bloque por cluster) y variación de ley mediante el coeficiente de variación dentro de un cluster. Como se menciona anteriormente, los clusters se forman desde el fondo hacia la superficie y luego se realiza una etapa de post procesamiento donde se remueven los clusters pequeños y bloques problemáticos (bloques como los de la Figura 2.7). Esto lo aplican en cuatro casos de estudios, en los que fueron agregando criterios al índice de similitud con el objetivo de ver su impacto. Primero se usa solo la distancia como índice de similitud, pero no logró generar clusters homogéneos considerando los criterios buscados. Luego se usó solo la ley en el índice de similitud generando un bajo coeficiente de variación, pero en el post proceso esa variación aumento. Por otro lado, al considerar el destino y distancia en el índice de similitud se generan clusters razonables en forma, ley, destino y tipo de roca. En un ejemplo de corto

plazo, considerando que la forma de los clusters es importante para llevarlo a cabo y que estos tienen que ser consistentes con la dirección de explotación, se define un índice de similitud que considera el punto de inicio y de término de minado. Los resultados muestran que se generan clusters en una cierta dirección preferencial pero el coeficiente de variación de la ley aumenta. En lo que respecta a los tiempos de ejecución, este se encuentra aproximadamente en seis minutos. A modo de conclusión, los autores comentan que al combinar índices de similitud de forma y destino se logra la mejor homogeneidad (en tamaño, tipo de roca, ley y destino), pero que las configuraciones van a depender del objetivo para lo que se generan clusters.

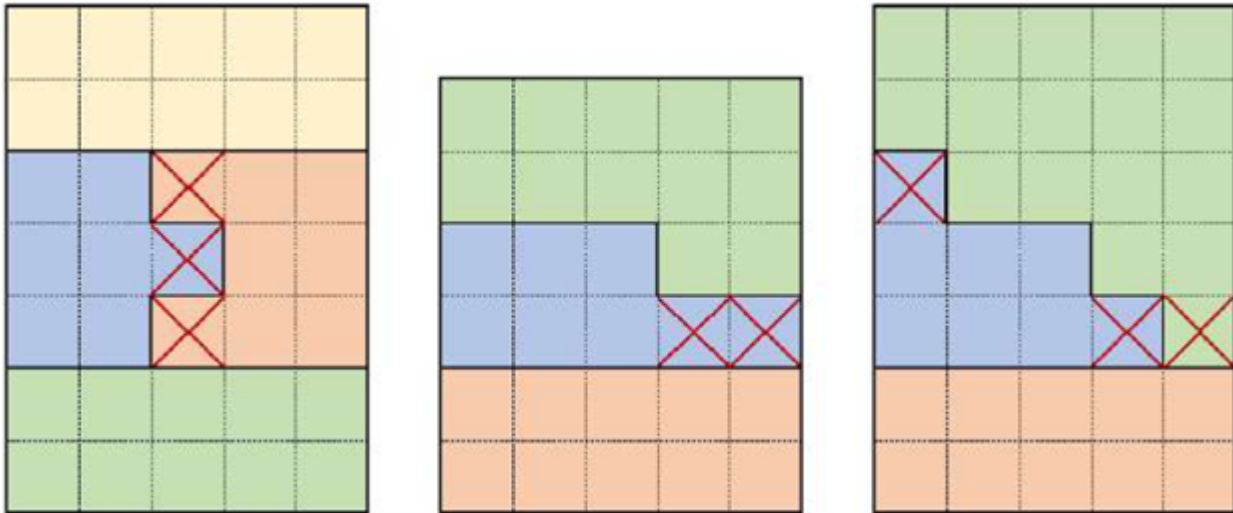


Figura 2.7: Esquema de bloques problemáticos marcados con una cruz roja (Nelis y Morales, 2021c).

En Tabesh et al. (2014) los autores utilizan el mismo algoritmo para generar clusters, pero resolviendo problemas asociados a la generación de fases. Primero se resuelve el problema de pit final de forma convencional para luego generar las fases (*push backs*), que se generan en primer lugar mediante un enfoque de parametrización que genera problemas de gap, pero mediante el enfoque binario que proponen los autores, se generan fases en las que se logra controlar el tonelaje de material y mineral de cada una. Una vez culminada la etapa de generación de fases, se utiliza el algoritmo para generar los clusters como en Tabesh y Askari-Nasab (2011). Estos clusters se usan dentro de un *MILP* para generar un agendamiento cuyo objetivo es maximizar el VPN. Finalmente, se aplica en dos casos de estudios donde se aprecia que el enfoque binario propuesto por los autores genera entre 2.1-4.7% mejor VPN en comparación al parametrizado. A diferencia de Tabesh y Askari-Nasab (2011) y Tabesh y Askari-Nasab (2013), en este estudio si se genera un agendamiento de los bloques.

En los trabajos de Tabesh y Askari-Nasab (2011), Tabesh y Askari-Nasab (2013), y Tabesh et al. (2014) se observa que no incluyen en sus trabajos la incertidumbre geológica que pueden presentar los datos, pero si lo hacen en Tabesh y Askari-Nasab (2019). En este trabajo, los autores utilizan el enfoque llamado *possible worlds* de Volk en donde generan distintos escenarios mediante simulación geoestadística de tipo de roca y ley, y luego se genera para cada “mundo” (*world*) sus propios clusters. Finalmente, se genera un modelo de clusters final para lo que los autores proponen cuatro metodologías distintas, donde tres de ellas consideran

todas las realizaciones (que se describen a continuación) y una no (EVA). En el primero (SRA) se calcula una matriz de clusters comunes (para ver si dos bloques que pertenecen a distinto escenario comparten el mismo cluster) y luego se calcula una frecuencia que en caso de ser mayor o igual a 0.5 para un par de bloques, esos quedan juntos en el modelo de cluster final. El segundo (HRA) es similar al primero, la diferencia radica en que este usa directamente la frecuencia como índice de similitud para generar los clusters finales. El tercero (KHRA), corresponde a un algoritmo híbrido entre el algoritmo *k-means* y agregación jerárquica para generar clusters en todas las realizaciones, luego utiliza la misma matriz y frecuencia de la primera forma y eso lo usa como índice de similitud para obtener los clusters finales. Estas metodologías se aplican sobre dos casos de estudios y a modo de comparación se utilizan los mismos criterios de Tabesh y Askari-Nasab (2013). El primer caso de estudio indica que la metodología SRA presentaba las mejores variaciones de ley (menor coeficiente de variación) y tipo de roca, pero generaba clusters muy grandes y pequeños en comparación a las otras tres metodologías. Considerando los resultados arrojados por cada realización, las otras tres metodologías presentaban variaciones similares y no así el SRA, pero las variaciones del EVA eran las peores en los que respecta a la ley y tipo de roca. Con respecto al segundo caso de estudio, las metodologías de KHRA y HRA presentaron buenos resultados, la diferencia entre ambas radica en el tiempo de ejecución que es mucho menor para el KHRA. A modo de conclusión, se observan las diferencias que existen al momento de generar clusters en presencia de incertidumbre geológica en donde dos metodologías mostraron entregar resultados más reales.

Gholamnejad (2008) genera un agendamiento de corto plazo considerando como restricción el acceso, desde una cierta dirección, a un bloque. En el estudio propone un modelo binario cuyo objetivo es maximizar el VPN, sujeto a ciertas restricciones entre las que se encuentra la relacionada al acceso. Para incorporar esta última restricción el autor considera que un cierto bloque  $i$  tiene otros ocho bloques que lo rodean (dentro de cada banco) y considera que para ingresar a dicho bloque  $i$  es necesario extraer tres bloques contiguos de cuatro formas diferentes, asegurando de esta forma que un cierto equipo de carguío pueda acceder al bloque  $i$ . El inconveniente del artículo es que no lo aplica en ningún caso de estudio.

Eivazy y Askari-Nasab (2012) proponen un modelo de optimización de agendamiento de corto plazo a través de un MILP. Este estudio corresponde a una mejora del trabajo de Askari-Nasab et al. (2011). A diferencia de otros trabajos, en este se consideran múltiples destinos posibles (distintas plantas de procesamientos, acopios (*stockpile*) y botaderos) para asemejarlo a lo que puede ocurrir en una operación. También considera distintas rutas o rampas debido a que un costo importante es el de transporte de material a alguno de sus posibles destinos y el modelo propuesto en función a la distancia (que se traduce en un costo) decide que rampa tomar. Otra cosa que incorporaron los autores es la de un avance direccional horizontal de extracción debido a su importancia al momento de la explotación de los bancos. La función objetivo consiste en minimizar distintos costos (mina, procesamiento, transporte, remanejo de material). El modelo asume que cada destino solo puede recibir material de un tipo de roca o una combinación de ellos. Con respecto a los acopios, estos generalmente están separados por tipo de roca y rango de ley y, además, se asumen homogéneos y que la ley de cada acopio corresponde a un promedio del material que lo compone. Una de las restricciones en el modelo con respecto a los acopios, es que su ley debe estar entre ciertos rangos mínimo y máximo cada periodo.

El modelo anterior es probado en un depósito de hierro ubicado en el sur de Irán. El agendamiento se realiza en un periodo de doce meses para cuatro bancos generando un total de 150 clusters mediante el método *fuzzy C-means* (no detallado en el estudio). Los bancos cuentan con dos accesos y la salida de la mina es la misma. Existen seis posibles destinos, dos plantas de procesamiento, dos botaderos y dos acopios, en donde cada planta y acopio cuenta con sus propias leyes y capacidades mínimas y máximas. En el estudio se comparan tres escenarios. En el primero se implementa el modelo sin restricción de dirección de minado, en el segundo se tiene una restricción de minado en dirección al sureste y en el tercero se tiene una restricción de minado en dirección al noroeste. En los tres escenarios se aprecia que los bloques se extraen por la rampa más cercana lo que era de esperarse dada la función objetivo. En lo relacionado a la producción, el tercer escenario presenta las menores fluctuaciones e incluso en los primeros meses es el único que llega a la capacidad máxima de planta. La ley es similar en los tres escenarios. En lo que respecta a los costos, el primer y segundo escenario presentan el menor y mayor valor respectivamente (diferencia de 0.13 MUSD aproximadamente). El tercer escenario resulta ser el mejor dado a las mínimas fluctuaciones en uso de equipos, ocupa la planta al máximo en los primeros meses (lo que se traduce en mayores ingresos) y es más práctico que el primero (aunque tenga costos un poco más elevados). No se tienen los valores de VPN del agendamiento. La diferencia con el trabajo de Askari-Nasab et al. (2011) es que en este último no se considera la restricción de dirección de minado.

Rehman y Asad (2010) generan un agendamiento de corto plazo que considera la extracción de bloques identificados en el plan de largo plazo para así sincronizar de la mejor forma ambos planes. Los autores proponen un MILP en el que la función objetivo se encarga de minimizar los costos, sujeto a ciertas restricciones, y esto lo prueban en una cantera de cemento lo que genera otro tipo de dificultades. El cemento es una mezcla de distintos componentes (elementos), por ende, lo hace diferente a la producción de metales como el cobre o hierro. No existe una diferenciación clara entre bloques de mineral y estéril, dado que un bloque puede tener bajo un elemento de interés, pero elevado en el resto. Es por eso, que algunas restricciones están relacionadas a la cantidad máxima y mínima de cada compuesto en la mezcla (en función a índices), de cada elemento de forma individual, de un máximo permitido de contaminantes, etc. En el caso de estudio se consideran tres periodos (dos días y medio cada uno) y como resultado, se generan ahorros de 123,177 USD.

Rahmanpour y Osanloo (2016) integran incertidumbre geológica en el proceso de planificación minera en el corto plazo. El objetivo es generar planes resilientes que sean capaces de tolerar la incertidumbre y disminuyan las desviaciones con respecto a un plan de producción de largo plazo. La función objetivo busca minimizar los costos sujeto a ciertas restricciones, como que se exceda un límite de contaminantes y que se tenga una cierta cantidad mínima de elemento de interés en la planta. Para estudiar el efecto de incertidumbre se generan 20 simulaciones condicionales de un depósito de oro en Irán cuya capacidad de planta es de 9,000 t/d. En el estudio la metodología se divide en 2 partes. En la primera se genera un agendamiento de corto plazo considerando un escenario E-type y las 20 simulaciones de los que se generan distintos KPIs (*Key Performance Indicator* en inglés) para conocer la performance del sistema en términos de calidad y cantidad de alimentación, y flujo de dinero. Mientras que, en la segunda parte, se buscan mejoras a los resultados anteriores. Los resultados del caso de estudio de la primera parte arrojan que tres escenarios llevan a una subproducción mientras

que otras tres, llevan a una sobreproducción. Con respecto a los KPIs, el de cantidad muestra que existe una probabilidad de subproducción, el de calidad indica que esta se encuentra bajo el mínimo de lo deseado y esto, evidentemente afectara el de flujo de dinero. Para trabajar con esta incertidumbre, por lo general se utilizan *stockpiles* (acopios) o se aumenta el ritmo de extracción. Para la segunda parte del estudio, los autores toman la segunda opción, de tal forma que se generan dos escenarios en los que la extracción mina aumenta un 5 % y 10 %. De tener un 87 % de probabilidad de subproducción con el agendamiento anterior, se pasa a un 13 % y 3 % aumentan la capacidad en un 5 % y 10 % respectivamente.

Villalba y Dimitrakopoulos (2016) generan un agendamiento de corto plazo con incertidumbre geológica. El modelo se basa en un enfoque estocástico (SIP) que optimiza simultáneamente el agendamiento de bloques y la flota de equipos. La función objetivo busca minimizar los costos considerando desviaciones con respecto a un objetivo, aspectos operacionales y utilización de equipos. Esta se compone por ocho partes (costo de extracción de material, costo asociado a los equipos de transporte, costos de traslado de los equipos de transporte a los frentes, penalización por incumplimiento de producción por pala dada la incertidumbre mecánica, penalización por no contar con espacio operacional necesario para acceder a un cierto bloque, penalizaciones relacionadas a incertidumbre geológica debido al no cumplimiento de cantidad y calidad de mineral que va a planta). El modelo se divide en dos etapas. La primera incluye minimizar los costos de extracción, movimiento de las palas, escasez de producción y espacio operacional (asociado al ancho necesario para los equipos). Mientras que, en la segunda etapa, estos costos se minimizan considerando incertidumbre geológica (distintos escenarios) y de disponibilidad mecánica (equipos). Cuenta con restricción de dirección de minado, como en enfoques anteriores, pero además (como aparece en la función objetivo) cuenta con restricciones asociadas al espacio operacional para lo que una cierta cantidad de bloques deben ser extraídos previamente a un cierto bloque. Para las palas y equipos de transporte, considera restricciones como de número máximo de palas en un sector, número máximo de viajes por equipo de transporte, etc.

El modelo lo aplican en un depósito de hierro para una planificación de 12 meses y se hace una comparación entre un modelo estocástico y determinista. En la Figura 2.8 se puede ver la comparación en el agendamiento. En primer lugar, la incorporación de las simulaciones (incertidumbre geológica) modifica la planificación en el corto plazo debido a que el determinista no logra la calidad necesaria de producto. En segundo lugar, se genera una disminución de los costos en aproximadamente 14 MUSD (considerando los dos enfoques) sienta la inserción de la incertidumbre de la disponibilidad mecánica de las palas la que mayormente lo afecta. En lo que respecta a la utilización de las palas y equipos de transporte no se aprecia mucha diferencia entre el enfoque estocástico y determinista, pero el estocástico requiere de la utilización de un menor número de equipos para lograr los objetivos de producción en 9 de 12 meses. En este artículo los autores no generan clusters.

Jamshidi y Osanloo (2018) presentan un MIP (*Mixed Integer Programming*) para el agendamiento de depósitos multi elementos contemplando múltiples destinos en un agendamiento de corto plazo. En la función objetivo se busca maximizar el VPN del proyecto para así minimizar las desviaciones entre el material mezclado y lo que se pide de mezcla para todos los destinos. En este tipo de depósitos, la calidad de producto no solo se basa en la ley del elemento de interés, sino que de otros elementos que puedan existir llamados elementos conta-






Figura 2.8: Agendamiento estocástico de corto plazo (izquierda) y determinista (derecha). (Villalba y Dimitrakopoulos, 2016).

minantes (por ejemplo, arsénico y fósforo en un depósito de cobre y hierro respectivamente). El modelo lo emplean en una mina de hierro, para lo que usan restricciones relacionadas a la mínima y máxima ley de hierro en el producto, y a la cantidad máxima de azufre y fósforo (para evitar castigos al momento de venta). El modelo lo aplican en un *push back* compuesto por 3,000 bloques. Para estudiar el efecto de tener distintos destinos, se analizan 10 posibles escenarios en donde 4 tienen solo un destino, 2 tienen dos destinos, 2 tienen tres destinos y solo 1 tiene cuatro destinos. Uno de los escenarios con 3 destinos posibles presenta un 15 % más de VPN en comparación al mejor escenario con un único destino. En general, los escenarios con múltiples destinos presentan mayores VPNs en comparación a un único destino.

Nelis y Morales (2021a) proponen un modelo de optimización de planificación en corto plazo que forma clusters mediante arcos de precedencia considerando *bloques representantes*. Esto lo aplican sobre un modelo de bloques compuesto por 864 SMUs, distribuidos en 2 bancos y con múltiples destinos en el que la ley de cobre se obtiene mediante simulación condicional. Utiliza en total 41 representantes (distribuidos según ciertos criterios, como por ejemplo, la variabilidad de ley) y estudia el efecto de agendamiento bloque a bloque, y usando los representantes con y sin restricciones de agendamiento en donde esta última cumple con las capacidades establecidas. Los resultados para cada caso de agendamiento se pueden ver en la Figura 2.9. Uno de los inconvenientes del trabajo, es que solo considera un escenario. Este algoritmo se utiliza en la presente tesis considerando un caso base y 20 escenarios más. Su explicación se puede ver en la sección 3.

En Nelis et al., (2021b) se presenta otra metodología para formar los clusters en donde se genera una solución factible mediante la entrega de formas predefinidos para luego comenzar un proceso de iteración mediante el método *column generation*. Las dimensiones de los clusters las define un ingeniero de minas y están relacionadas a los tamaños de los equipos. Esto lo aplican en un caso de estudio de agendamiento de corto plazo de cuatro bancos y cuenta con tres destinos posibles. Se generan dos escenarios principales, uno de política de destinos y otro con recuperación variable en donde se compara el efecto de tener y no tener mezcla. En

ambos escenarios se hace la comparación entre destino por ley de corte (desde ahora caso base) y lo obtenido con el modelo. En el caso de política de destinos, todos los escenarios estudiados obtuvieron menor valor en comparación al caso base. Por otro lado, en el escenario con recuperación variable, al incluir mezcla se obtuvo un mejor resultado en que el caso base y sin mezcla.

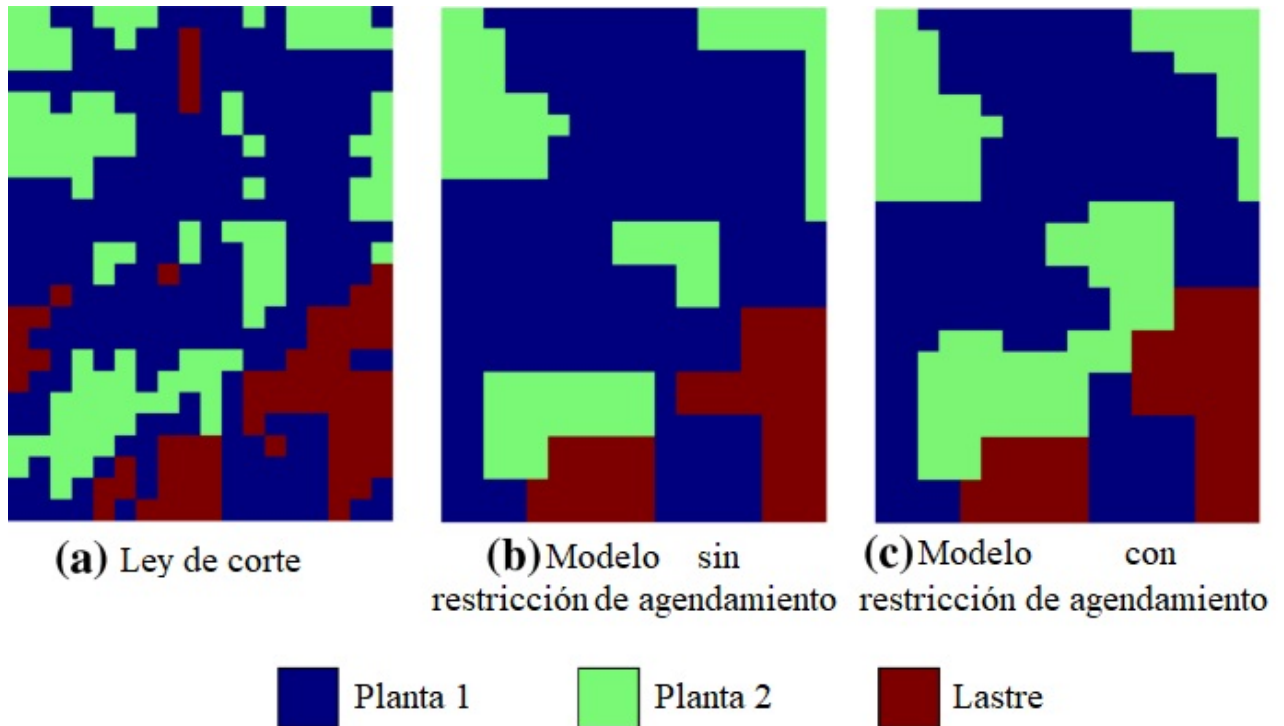


Figura 2.9: Distribución manual y óptima de clusters de un banco. (a) ley de corte, (b) diseño manual, (c) diseño óptimo. (Nelis y Morales, 2021a).

Nelis y Morales (2021c) hacen una comparación del modelo propuesto en Nelis y Morales (2021a) y en Nelis et al., (2021b), donde ambos tienen como objetivo el agendamiento de corto plazo y resolver el problema de la generación de clusters. Los autores comentan que a diferencia del modelo de Nelis y Morales (2021a), en Nelis et al., (2021b) no presentan inconvenientes relacionados a formas de clusters problemáticas dado que las formas que pueden tomar los distintos clusters ya son factibles, pero, por otro lado, es muy difícil controlar el avance de la extracción debido a los arcos de precedencia horizontales.

Para comparar un modelo con el otro, los autores lo aplican a un modelo de bloques compuesto por dos bancos y un total de 784 SMUs. El modelo propuesto en Nelis y Morales (2021a) (desde ahora “primer modelo”) genero un total de 35 clusters (en el input se dan 35 representantes) mientras que el modelo con el que se compara en este trabajo (desde ahora “segundo modelo”) usa un total de 36 clusters. Ambos modelos generaron formas de clusters conectadas, pero diferentes, con tamaños que permiten la selectividad del equipo de carguío, aunque el primer modelo genero formas más irregulares generando clusters problemáticos. Por otro lado, permiten maximizar el beneficio y delimitar las zonas de estéril y mineral (en esto ambos son similares). Al comparar los beneficios, ambos fueron inferiores (como es de esperar) en comparación al caso de mejor destino (extracción bloque a bloque) mientras que, entre los

modelos principales, el segundo supera levemente al primero. Esto puede estar relacionado a que en el primer modelo es muy importante la ubicación del bloque representante y que el segundo modelo cuenta con muchas geometrías de clusters para tener mayor flexibilidad. En lo que respecta a tiempos de ejecución, el primero es mucho más rápido que el segundo precisamente por la cantidad de variables con las que trabaja el segundo. Para finalizar, en el primer modelo es posible definir restricciones de agendamiento mientras que en el segundo no, dada la cantidad de variables que ya posee. Cada modelo tiene sus pros y sus contras, por ende, es importante la experiencia de un ingeniero para llevar a cabo este proceso.

## 2.4. Geometalurgia

Muchas veces el parámetro más importante en los estudios es la ley, y además por que afecta directamente los ingresos, pero existen otras variables que también lo afectan de manera indirecta reduciendo el valor (disminuyendo la recuperación o por la presencia de elementos contaminantes), o aumentando los costos de minado o tratamiento (conminución, uso de reactivos, etc.). Aquí es donde entra la geometalurgia, que busca responder a la pregunta “¿cómo el bloque X se comportará durante el proceso?” (Dominy et al., 2018). Tradicionalmente este tipo de variables se consideran fijas para todos los bloques, como la recuperación, que pertenecen a un cierto dominio geológico, pero en realidad no debería ser de esa forma.

La geometalurgia es un área interdisciplinaria que busca integrar la geología y el procesamiento de minerales que involucra el entendimiento y la medición de propiedades relevantes para el éxito del proceso (Lund y Lamberg, 2014). En este último trabajo también se comenta los pasos que se llevan a cabo en un programa geometalúrgico en la industria y que el punto más débil del proceso ocurre al momento de seleccionar las muestras dado que un número pequeño de estas deben representar grandes toneladas.

En Dominy et al. (2018) se define la geometalurgia como una actividad interdisciplinaria que integra geología, minería/ingeniería geotécnica, metalurgia, economía de minerales y parámetros geoambientales para maximizar el valor económico del proyecto, reducir el riesgo, construir resiliencia y demostrar un buen manejo del recurso. Su objetivo principal es mejorar la rentabilidad del proyecto.

Generar modelos geometalúrgicos puede incluir, entre otras, mejoras en (Coward et al., 2009):

- Diseño de mina y de proceso.
- Optimización del proceso.
- Pronóstico de ingresos y costos.
- Mejoras tácticas en la planificación y estrategias de mezcla en el corto a mediano plazo.

En Coward et al. (2009) se genera una clasificación de variables geometalúrgicas, las que puede ser primarias o secundarias. Las variables primarias, son aquellas que corresponden a propiedades intrínsecas del depósito como la ley, masa, granulometría, entre otras. Por otro lado, las variables secundarias (o de respuesta), son aquellas que están relacionadas a la respuesta a algún proceso como la utilización de energía, la chancabilidad, recuperación

metalúrgica, moliendabilidad, plasticidad, etc. (Figura 2.10). Las variables secundarias afectan a un bloque en su valorización económica y en su forma de procesamiento de manera directa. Por ejemplo, la recuperación metalúrgica se utiliza directamente en la fórmula de valorización, mientras que el costo de utilización de energía (que puede estar relacionado al consumo energético de los molinos o chancadores) al costo de procesamiento. Las variables primarias, si bien no afectan directamente a la valorización de un bloque, lo hacen de manera indirecta. Por ejemplo, el tipo de alteración puede afectar al pH que se tiene en una celda de flotación haciendo necesario la utilización de reactivos (como cal) para tener las condiciones idóneas para el proceso. Por otro lado, el tamaño de grano o la textura de las rocas pueden afectar a la liberación y esto afectar al tiempo de residencia en el molino.

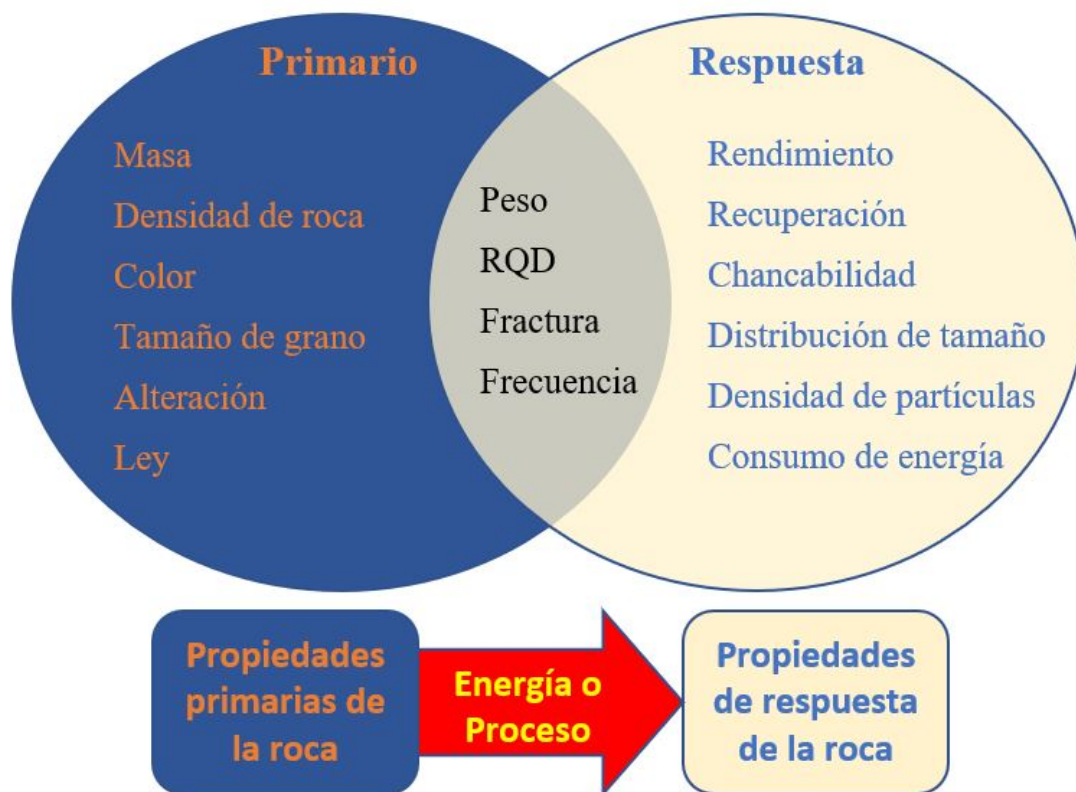


Figura 2.10: Clasificación de las variables geometalúrgicas primarias y secundarias (o de respuesta) (Modificado de Coward et al. 2009).

Entre las variables secundarias se mencionan las de recuperación, moliendabilidad y chancabilidad. La recuperación es una de las variables más importantes en el proceso dado que mide la cantidad de un cierto tipo de elemento de interés que se recupera o llega al concentrado final, con respecto a una alimentación inicial. Depende de la molienda realizada al material (liberación), de los elementos contaminantes y condiciones en la celda. Esta se puede medir en laboratorio en celdas de flotación rougher. Por otro lado, la moliendabilidad y chancabilidad miden la energía necesaria para poder reducir el material a un cierto tamaño y esto depende, entre otros, de la dureza y los minerales que componen al material. Existen distintos ensayos para medir estas variables entre los que se encuentran el BWi (*Bond Work Index*) y SPI (*SAG Power Index*) en la que el primero se usa para molinos de bolas mientras que el segundo para molinos semi-autógenos (SAG) (Casali, 2019).

La conexión entre las variables primarias y secundarias es compleja. La dificultad que presentan las variables geometalúrgicas es que no son aditivas, por lo tanto, al momento de estimarlas mediante kriging se puede generar sesgo y se recomienda utilizar variables *proxies* que si sean aditivas (Dunham y Vann, 2007). Para genera un modelo geometalúrgico, se recomienda primero generar una caracterización de las muestras (descripciones geológicas a meso y microescala, y ensayos metalúrgicos) para luego encontrar relaciones entre las variables de respuesta y aquellas que son intrínsecas de las rocas, y describir su relación mediante algún modelo matemático para pasar de las primarias a las secundarias. Posterior a eso, a través de simulación geoestadística, se puede generar un modelo geometalúrgico que luego se puede usar en los procesos como de planificación minera (Deutsch, 2013).

Otra clasificación que se puede hacer en geometalurgia, es la relacionada al horizonte temporal, pudiendo ser estratégicos y tácticos. La geometalurgia estratégica tiene un horizonte temporal de largo plazo y tiene como objetivo generar un modelo que ayude a guiar la minería y a la toma de decisiones de procesamiento en lo que respecta a la producción de metal y al flujo de dinero, usando todo tipo de información posible (información metalúrgica, mineralógica, etc.). Además, este modelo puede fortalecerse usando información adquirida en el programa táctico de geometalurgia. Este último, se relaciona a un horizonte temporal de corto a mediano plazo y presenta un nivel de información mayor en comparación al caso estratégico debido al uso de pozos de tronadura. Ayuda de una mejor forma en la asignación de destino de un bloque, ya sea botadero, planta o *stockpile* (Dominy et al., 2018; McKay et al., 2016).

Por otro lado, la geometalurgia no solo es útil al momento de querer mejorar el negocio minero en términos económicos, sino que también ambientalmente (como se menciona en la definición) por ejemplo, en distintos elementos o minerales y sus respectivas concentraciones que llegan al relave (un caso puede ser el de pirita que bajo ciertas condiciones puede generar relave ácido).

Son distintos los estudios que tratan la geometalurgia en conjunto con geología para estudiar sus efectos. A continuación, se comentan algunos estudios relacionados a los procesos de molienda y flotación.

### 2.4.1. Geología y Geometalurgia

En un depósito geológico existen distintos tipos de alteraciones, compuestas por distintos minerales de mena y ganga, y que presentan distintas texturas entre ellos, y generadas bajo diferentes condiciones fisicoquímicas que pueden afectar de una u otra forma a los procesos de molienda y flotación.

En Cropp et al. (2013) se comenta sobre el efecto que puede tener en el proceso de flotación las distintas texturas que presentan los minerales de mena con los de ganga y el tamaño de grano, que juegan un rol muy importante en la recuperación y ley. En la Figura 2.11, se muestra una curva teórica máxima de ley-recuperación de un concentrado y si el concentrado se encuentra bajo esta curva, como suele ocurrir, es resultado de la textura, tamaño de grano y mineralogía o de las condiciones de flotación de la planta. En la parte izquierda de la figura, se aprecia que en la zona de alta recuperación y baja ley se encuentran por lo general partículas que no tiene una liberación completa (mena y ganga); mientras que en la zona de

alta ley y baja recuperación partículas bien liberadas (mena). El inconveniente con el primer caso es que debido a los minerales ganga la ley disminuye, y con el segundo es que debido a su menor tamaño no se adhieren a las burbujas. Es por ese motivo, que en la parte derecha de la figura se observa que si nos encontramos en un punto bajo la curva teórica máxima puede ser por dilución (debido a que otros minerales llegan al concentrado) o por pérdidas.




Figura 2.11: Curva teórica máxima de recuperación-ley con texturas (izquierda) y motivo por el cual un cierto concentrado se encontraría bajo esta curva (derecha) (Cropp et al., 2013).

Los mismos autores resumen las principales influencias de la mineralogía y la textura en la Figura 2.12, en la que las causas del 1 al 3 están relacionadas a pérdidas al relave mientras que del 4 al 7 a dilución en el concentrado. Cada uno de los números representa lo siguiente:

1. Minerales de mena finos. Al ser finos, no se adhieren bien a las burbujas y se pierden.
2. Minerales de mena encerrados. No llegan al concentrado porque son muy grandes, y pesados, y no flotan o porque no presentan una cara libre para ser recolectado.
3. Recubrimiento de minerales económicamente importantes. Recubrimiento de la superficie de minerales de mena por minerales de ganga hidrofílicos como fosfatos, filosilicatos, arcillas, entre otros.
4. Minerales de ganga al concentrado. Esto se debe a que están rodeados por minerales de mena.
5. Minerales de ganga arrastrados al concentrado. Esto se debe a que algunos minerales de ganga flotan naturalmente.
6. Minerales de ganga “activados”. Iones de cobre que se encuentran libres pueden adherirse a la superficie de minerales de ganga convirtiéndolos en hidrofóbicos.
7. Distribución de elementos perjudiciales. Esto está relacionado a la presencia de elemen-

tos como el arsénico.




Figura 2.12: Distintas causas de una recuperación o ley de cobre menor a la esperada en un concentrado de flotación, mostrado en función al tamaño de grano para minerales de mena y ganga (Cropp et al., 2013).

En distintos estudios se habla de las distintas causas comentadas anteriormente y también del efecto de algunos minerales de ganga, en especial de las arcillas y filosilicatos.

Los filosilicatos son minerales de alteración muy comunes. Están compuestos básicamente por capas de tetraedro de silicio “T” y octaedros de aluminio “O”. La capa T está compuesta por unidades de átomos de silicio rodeados por átomos de oxígeno, y entre unidades se conectan por un átomo de oxígeno apical. Mientras que las capas O, se componen por un catión central que está ligado a seis grupos hidróxidos en simetría octaédrica. Este catión puede ser  $Al^{3+}$  o  $Mg^{2+}$ . Casi todos los minerales arcillosos presentan una estructura T-O (1:1) como por ejemplo la caolinita, o T-O-T (2:1) como en el caso de las esmectita (Basnayaka et al., 2017; Ndlovu et al. 2014). Debido a sustituciones isomórficas de los cationes, las caras de las arcillas pueden tener una carga negativa independiente del pH. Por otro lado, debido a que en los bordes se tienen enlaces rotos estos pueden tener una carga positiva o negativa que es dependiente del pH. Por lo general, debido a las condiciones de flotación la carga de los minerales suele ser negativa (Basnayaka et al., 2017).

Algunos de los efectos que este tipo de minerales puede generar en el proceso de flotación, que se mencionan en Farrokhpay y Bradshaw (2012), Farrokhpay et al. (2016), Ndlovu et al. (2013) son los siguientes:

- Recubrimiento de la superficie de minerales económicamente importantes y burbujas.
- Consumo de reactivos (lo que genera que haya menos reactivos para los minerales

importantes y modificar la estabilidad de la espuma).

- Aumento de la viscosidad de la pulpa.
- Modificación de la estabilidad de la espuma.
- Transferencia de grandes cantidades al concentrado.

Farrokhpay y Bradshaw (2012), comentan que el recubrimiento en los minerales puede ocurrir debido a las diferentes cargas en las caras. Según estudios, el efecto que presenta la caolinita o ilita en la recuperación de cobre no es tan significativo como el caso de la montmorillonita o la chamosita (Bulatovic et al., 1999). Las arcillas que se hinchan (o se hidratan) son capaces de aceptar grandes cantidades de agua y eso conlleva a un aumento de volumen. El agua puede estar presente en arcillas como grupos hidroxilos, en posiciones entre las capas, absorbida en superficie, y en los poros entre minerales de arcilla. La capacidad de hinchamiento de los minerales de arcilla afecta la reología de la pulpa, haciéndola más viscosa. En un estudio (Zhou, 1997), se demuestra que a medida que aumenta la salinidad del agua, la capacidad de hinchamiento disminuye. El cambio en la estabilidad de las burbujas, de la viscosidad, se debe al arrastre de partículas finas y según estudios, una concentración de 5-12 wt % puede generar una alta viscosidad, lo que puede afectar al mismo tiempo a la movilidad de las burbujas, partículas y burbujas mineralizadas en la pulpa. También pueden llegar arcillas unidas a burbujas al concentrado, generando una disminución de la ley.

En Farrokhpay et al. (2016), se estudia la diferencia de efecto en flotación de arcillas que se hinchan (montmorillonita) y las que no (caolinita e ilita) con el objetivo de ver los distintos efectos en la flotación de minerales de cobre mediante la ley de cobre en el concentrado, recuperación y características de las burbujas. Se observa que la ley de cobre disminuye a un 1 % al aplicar un 30 % de caolinita y un 15 % de montmorillonita, y a un 5 % con un 30 % de ilita en el concentrado. Esto puede estar relacionado a que estos minerales llegan por arrastre al concentrado o a cambios reológicos (viscosidad) de la pulpa. En lo que respecta a la recuperación, con un 15 % de montmorillonita, la recuperación baja de un 90 % a un 80 %, mientras que con un 30 % de ilita y caolinita la recuperación baja hasta el 88 %. Esto se puede observar en la Figura 2.13. El efecto que genera la montmorillonita puede deberse a un aumento en la viscosidad de la pulpa, lo que generaría una disminución de la interacción burbuja-partícula o también la movilidad. Por otro lado, no se puede olvidar el efecto de revestimiento de los minerales. En un análisis de laboratorio del concentrado, se aprecia un aumento de  $\text{Al}_2\text{O}_3$  y  $\text{SiO}_2$  al aumentar el contenido de arcilla. La montmorillonita y caolinita generan un impacto alto en la estabilidad de la espuma, mientras que la ilita el menor (o nulo) impacto. Con respecto a la distribución del tamaño de burbuja, la montmorillonita y la caolinita (en su concentración más alta) afectan la distribución de tamaños, generando burbujas muy pequeñas, y la ilita no muestra un impacto significativo en ellas. En comparación de la ilita y caolinita, que tiene enlaces fuertes que unen las distintas capas, las capas que componen la montmorillonita son débiles y ahí es donde entran las moléculas de agua fácilmente.

En la actualidad, se pasa por un proceso de escasez hídrica por lo que algunas compañías mineras comenzaron a emplear agua desalinizada. En Cruz et al. (2020), se genera la desalinización parcial de agua de mar mediante la extracción de calcio y magnesio mediante la inyección de  $\text{CO}_2$  gaseoso para mejorar la recuperación de calcopirita. Al analizar agua de






Figura 2.13: Efecto de minerales de arcilla (ilita, caolinita, montmorillonita) en la flotación de minerales de cobre (Farrokhpay et al. 2016).

mar no tratada a un pH 11 se observa un aumento en la recuperación de calcopirita y un muy leve aumento de la ley de cobre en comparación a un agua no tratada a un pH 11 debido a que los iones divalentes disminuyeron.

En lo que respecta a las texturas, en Tungpalan et al. (2015) se realiza un estudio mineralógico que incluye identificar la composición de los minerales y sus texturas. En distintos trabajos, la textura se clasifica algo cualitativo basado en abundancia de minerales, comportamiento metal/mineral, forma, modo de ocurrencia del mineral de interés, o la asociación entre minerales. Pero, el tamaño del mineral (tanto del de interés como estéril) es el que más impacta en el comportamiento del proceso. En este trabajo, se utiliza el tamaño de grano y asociación mineral para interpretar la recuperación de cobre en flotación. Se generaron cuatro muestras y dos clases para el estudio. Las clases se generaron por ciertas características (como alteración, ley de metal de interés y otros minerales). En una clase se tenía la muestra A y B, y en la otra a las muestras C y D. Como resultados, se observó que las muestras A y C presentaron mayor recuperación de cobre, pero una menor ley en comparación a las muestras de sus clases, B y D. Mineralógicamente, las muestras A y B contienen abundante calcopirita y menor bornita, mientras que las muestras B y D contienen abundante bornita, algo de digenita y calcosina, otros sulfuros de cobre y muy poco (o nada) de calcopirita. En lo que respecta al tamaño de grano, las muestras A y C contienen granos más gruesos de sulfuros de cobre. Se puede observar, que las muestras con tamaño de grano más gruesos tendrían mayor recuperación de cobre dado que al generar la molienda se tendrá, para el mismo

tamaño de partícula, mayor grado de liberación. Por otro lado, la asociación mineralógica también afecta la recuperación. En una partícula de la muestra B se observa que el mineral de cobre tiene una alta relación de contacto con minerales de ganga mientras que en una partícula de la muestra A, se observa que los minerales de cobre están más en contacto con pirita (mineral ganga, pero flotable). Es por este motivo, que la ley de cobre es menor en la muestra A con respecto a B. Se puede observar la importancia de una buena caracterización de las muestras y la importancia de incluir el tamaño de grano en el estudio. Incluir las texturas de los minerales, en la caracterización geometalúrgica genera mejores predicciones sobre la recuperación de cobre.

En lo que respecta al proceso de molienda, los minerales pueden participar en reacciones como oxidación y reducción, entre otras. En Fullston et al. (1999) se estudia el “*zeta potential*” de sulfuros de cobre en función del pH y en estado de oxidación. Se observa que el cambio en el “*zeta potential*” se debe a una capa de hidróxido de cobre que cubre a sulfuros deficientes en metal y enriquecidos en azufre, y al aumento de la capa de hidróxido de cobre con el aumento de la condición de oxidación. De los minerales analizados, observa que la reactividad aumenta desde calcopirita, covelina, bornita, enargita, tenantita y finalmente calcosina, siendo este muy activo eléctricamente. En Zhao y Peng (2012), se estudia el efecto que tiene la oxidación de calcopirita y calcosina, y su posible interacción con bentonita. Al analizar, post molienda, la calcopirita y calcosina se observa que ambas presentan oxígeno, pero la segunda más que la primera. Esto se comprueba con análisis XPS. El i.e.p. se modifica en ambos minerales, por su estado de oxidación, siendo el de calcosina el que sufre el mayor cambio y que, a un pH de 9, podría sufrir cubrimiento por bentonita dado que esta última tendría carga negativa y la calcosina una carga positiva. Por otro lado, calcopirita no sufriría ningún efecto.

En lo que respecta a las texturas y mineralogía, en Diaz et al. (2019) se realiza un estudio para verificar si las texturas a meso y microescala tienen algún efecto en el proceso de molienda que no se pueda describir con el índice de conminución. Para llevar a cabo el estudio, se tomaron dos muestras A (pórfido de cobre) y B (depósito de menor escala, asociado a vetas hidrotermales hospedados en intrusivos granitoidales) escogidos en función a contexto geológico similar. Después de realizar un ensayo de Bond a las muestras, se observa que muestra un BWi muy similar. De las pruebas de molienda se pudo observar que la muestra B presenta rápido decaimiento de P80 en los primeros diez minutos de molienda y que ambas muestras presentan un tamaño de grano similar al final de la prueba. Por otro lado, que la muestra A se muele más rápido en la fracción fina mientras que la muestra B se muele más rápido en la fracción gruesa (0.25 mm). Otra cosa que se pudo observar es que al tener la muestra B un tamaño de grano más grueso, los tamaños más finos se comportan de una forma más homogénea mientras que los tamaños más gruesos no (indicando que estos podrían generar más fragmentos de roca y, además, con mayor cantidad de grietas o planos de debilidad). Esto último podría explicar que la muestra B tenga un rápido decaimiento en su P80. Mineralógicamente hablando, la muestra A presenta mayor cantidad de filosilicatos. Según Ndlovu et al. (2013) los filosilicatos en un molino pueden generar inconvenientes como reducir la capacidad, la eficiencia y rendimiento debido a que son pequeños y maleables. Este tipo de minerales también podrían afectar en el BWi, indicando que se habla de un tipo de roca duro cuando en verdad no lo es. En términos de estructuras, en las muestras A se observaron vetillas rellenas de yeso, cuarzo y filosilicatos que no aportan a obtener granos de menor tamaño dado que en todo momento la muestra A presentaba tamaños de grano

más gruesos lo que indicaría que es más importante el tamaño de grano que alguna microestructura. Con esto se puede apreciar que la información geológica puede aportar información valiosa sobre el comportamiento durante la molienda y en el parámetro geometalúrgico como el BWi.

En la siguiente sección se aprecia el impacto que puede generar aplicar información geometalúrgica en planificación minera.

## 2.5. Geometalurgia y Planificación Minera

En la sección 2.2.1 se observa que los modelos estocásticos incorporan principalmente incertidumbre de leyes, pero no variables geometalúrgicas. En distintos estudios se han incluido este tipo de variables con el objetivo de estudiar el impacto de estas en planificación minera.

En Navarra et al. (2017) se aplica un modelo de optimización de dos etapas sobre distintas unidades geometalúrgicas considerando distintos modos de operación de la planta, que considera un conjunto de planes mineros viables y dependiendo del proceso aplicado, dependerá el valor del proyecto. Para la correcta evaluación de los costos y el valor recuperado para un cierto periodo y escenario geológico se usa el método metaheurístico *Variable Neighbourhood Descent*. En este trabajo se reemplaza el límite de capacidad de procesamiento y la ley de corte, por el *throughput* (que considera el tiempo anual que se puede usar el concentrador menos las revisiones técnicas) y *yield* (con lo que se decide que bloques procesar en función a su valor). Esto se aplica sobre un caso de estudio que tiene dos unidades geometalúrgicas que no se indica en función a que las caracterizan solo que contienen distintas características mineralógicas. Los resultados arrojan que se tiene un mejor VPN y uso de concentrador cuando se consideran dos modos operacionales para las dos unidades geometalúrgicas. Además, la vida de la mina se extiende en dos años. Pero una limitantes del trabajo es que no considera *stockpiles* y los bloques con *yield* bajo, los trata como lastre en vez de considerar mandarlos a *stockpile*, pero las pérdidas son dos órdenes de magnitud menores (según el estudio). En Navarra et al. (2018a) se comenta porque se escoge una metaheurística, sabiendo que no entrega un resultado óptimo, pero el resultado que entrega lo hace en un periodo de tiempo corto y no agrega ningún parámetro de ajuste a diferencia de otras metaheurística.

En Navarra et al. (2018b) se presenta una optimización estocástica de dos etapas para incluir modelos geometalúrgicos (generados considerando aspectos como la mineralogía, liberación, texturas y química mineralógica) en planificación de largo plazo en donde la primera etapa se encarga del agendamiento de los bloques (cuando serán minados) mientras que la segunda etapa se encarga de decidir que fracción del bloque procesada considerando un escenario geológico. Los autores proponen distintos modos operacionales en función a características composicionales y morfológicas de los bloques. Es por eso que el valor de un cierto bloque depende del costo de procesamiento del modo operacional, la recuperación de un cierto elemento de interés en el modo operacional escogido y del costo de venta que tenga ese elemento recuperado en ese modo operacional (que puede variar según la calidad del producto). Por otro lado, cada modo operacional cuenta con sus propias capacidades de producción. La ecuación encargada de asignar valor a un cierto bloque considera que el elemento de interés se recupera solo donde dice el modelo que debe recuperarse. También considera que cada bloque tiene solo un elemento de interés. Los planes de largo plazo asu-

men que en el corto plazo existe tal flexibilidad que los bloques pueden procesarse bajo un modo operacional que maximice su valor lo que en verdad no ocurre porque los bloques no se extraen de forma independiente.

El modelo lo aplican a un caso de estudio de un modelo de bloques compuesto por 9,953 bloques que se resuelve mediante el algoritmo *Variable Neighbourhood Descent* (método metaheurístico). A modo de simplificación las variables geometalúrgicas se agrupan dentro de un factor geometalúrgico que se correlaciona linealmente con la profundidad siendo este cero en superficie y uno en profundidad. Para el estudio se tienen dos formas de operar, la primera cuenta con un modo operacional (Modo I) mientras que la segunda cuenta con dos modos operacionales (Modo I y Modo II). Cada modo operacional cuenta con sus respectivos costos de procesamiento, recuperación, valor de procesamiento y valor de rendimiento. Los resultados muestran que, al tener dos modos operacionales en vez de uno, se tiene un mayor pit final (porque es más favorable para los factores geometalúrgicos mayores que se encuentran en profundidad), se genera un mayor VPN y extiende la vida de la mina en dos años.

A diferencia de Navarra et al. (2017), en Navarra et al. (2018b) se utiliza la ley de corte en vez del *yield*, y los bloques son ordenados en función a la ley de corte y el límite lo marca el tiempo máximo de utilización que del concentrador y, por otro lado, este artículo considera el uso de *stockpiles*. En Navarra et al. (2018b), como en Navarra et al. (2017), no se comenta en mayor detalle sobre la planificación ni de cómo funcionan los modos operacionales.

En el trabajo anterior se menciona que los modelos geometalúrgicos están basados en aspectos como la liberación, textura, etc. porque son influyentes en la performance del proceso. El término textura suele utilizarse principalmente a microescala y describe el entrecrecimiento de los minerales, su asociación, tamaño de grano, diseminación e inclusión (Dominy et al., 2018). Esto es muy útil cuando se quiere conocer la relación existente entre un mineral de interés y otro mineral que puede ser penalizado en el concentrado o que puede generar dificultades durante el proceso. En estos casos, el grado de liberación, que puede estar asociado a la molienda, es importante. Pero, por otro lado, se debe considerar que el proceso de concentrado tiene limitantes (por ejemplo, que no recupera bajo un cierto tamaño).

Otro estudio en donde se comenta la importancia de las propiedades geometalúrgicas de los depósitos es en Van den Boogaart et al. (2011). En dicho estudio, los autores utilizan información obtenida con MLA (*Mineral Liberation Analyzer*) de mineralogía y estructuras de las muestras. El MLA puede aportar información sobre composición mineralógica, distribución de tamaño de granos, asociación mineral y fases. Tal como se menciona en la sección 2.4.1 y en este artículo, se comenta que dependiendo de las características de los minerales se pueden obtener distintos resultados en relación al procesamiento escogido (por ejemplo, distinto tamaño de grano puede cambiar el tamaño de liberación, el entrecrecimiento de los minerales puede complicar la liberación de los minerales de interés, entre otros). En el estudio los autores buscan determinar el impacto que tienen variables geometalúrgicas mediante el uso de información obtenida por MLA de 29 cortes transparentes de un depósito de Cu-Ag. A modo de simplificación los autores consideran que la liberación de los minerales de interés se obtiene si se muele a su respectivo tamaño de grano, los costos de procesamiento están dominados por el consumo energético del molino, y los ingresos son proporcionales a la cantidad de mineral liberado en el molino. Si bien los autores no generan un agendamiento de bloques,

los resultados arrojan que los ingresos podrían aumentar en un 3.9% en comparación al caso en el que no se utiliza este tipo de información. Por otro lado, también comentan que con un mayor número de muestras los ingresos podrían sufrir aumentos significativos.

Del Castillo y Dimitrakopoulos (2016) generan un mecanismo de política de destino para depósitos polimetálicos para aumentar de esta forma el valor de un proyecto. En este trabajo se propone la creación de coaliciones (clusters) utilizando *Shapley Value* (que es una línea de estudio de la teoría de juegos cooperativa en donde los integrantes de la coalición, que en este caso serían los bloques, se unen para aumentar sus utilidades) que en el proceso de toma de decisiones se usan variables geometalúrgicas del depósito, incertidumbre geológica y requerimientos de mezcla. El objetivo de integrar información geometalúrgica es porque la recuperación y performance metalúrgica de la planta dependen de un conjunto de bloques y no de la percepción de que los bloques se procesan solos. Para reducir el costo computacional, los autores proponen un pre-proceso del depósito agrupando bloques (que no se detalla en el estudio) con características similares mediante *k-means++* con el objetivo de generar previamente los clusters. Otra simplificación del estudio es que el agendamiento de los bloques se considera fija, es decir, ya se sabe previamente que bloques se extraen en qué periodo. De esta forma el proceso de optimización se centra en determinar las distintas coaliciones envueltas en un periodo. Esto lo hacen a través de múltiples escenarios geológicos para considerar la incertidumbre de los datos.

El caso de estudio corresponde a un depósito de cobre-oro que se extrae a cielo abierto y con seis distintos destinos. También se tiene información de contaminantes (arsénico y sulfuro) y de litología. Cada destino puede recibir bloques de cierta litología y cada uno cuenta con sus propias curvas de recuperación que dependen de la ley de alimentación y que no son lineales. Esto se puede ver en la Figura 2.14. El modelo se compara con un caso determinístico y los resultados muestran que el VPN mejora en un 5.6%. En lo que respecta a las restricciones (ley de alimentación y arsénico), estas mejoran en comparación al caso determinista pero igual se violan en algunos periodos lo que puede estar relacionado a que el agendamiento de los bloques es fijo. Una limitación que resaltan los autores es que las incertidumbres geológicas y geometalúrgicas no están directamente integradas en el proceso de coalición, sino que solo en el proceso de optimización por eso recomiendan implementar un enfoque estocástico del *Shapley Value* que represente un set de escenarios.

En Garrido et al. (2017) se genera un agendamiento considerando variables geometalúrgicas en el proceso de optimización. Los autores comentan que las arcillas pueden generar problemas metalúrgicos en lo que respecta al proceso de flotación como la caolinita, illita, etc. y que, en caso de no controlarse, pueden generar dificultades en la recuperación metalúrgica, por ejemplo, de calcopirita o covelina (como se menciona en la sección 2.4.1). Los autores generan un agendamiento de optimización multi-objetivo que puede minimizar la variación de arcilla a procesarse en el corto plazo y maximizar el VPN. Para solucionarlo, consideran un método metaheurístico llamado *Tabu Search*, que encuentra soluciones con un alto nivel de exactitud en poco tiempo. Para minimizar la cantidad de arcillas, los autores proponen usar dilución (pero de arcillas) en donde la arcilla que hace de “mineral” corresponde a la dominante en la zona de alteración donde se encuentren. Como resultados, el caso base y de dilución entregan resultados similares en lo que respecta a las leyes y tonelaje extraído. La dilución disminuye en gran parte de los periodos, generando una alimentación más homo-

génea. Esto permite tener menores pérdidas económicas que los autores no consideran en el estudio. La optimización no considera un ritmo de explotación o de procesamiento constante en el tiempo.

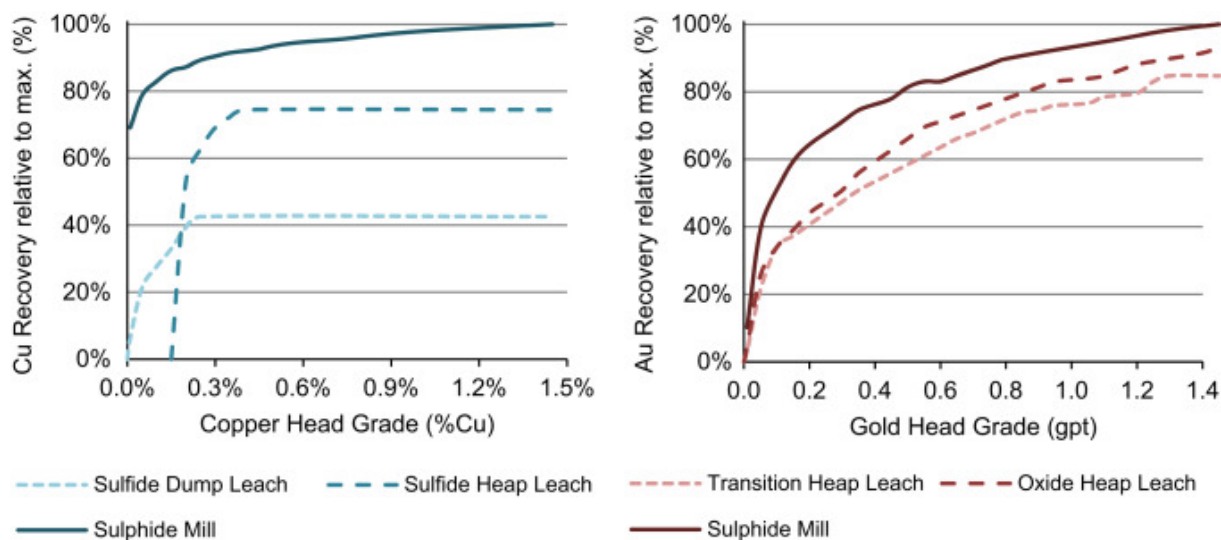


Figura 2.14: Curvas de recuperación en función a la ley de alimentación (Del Castillo y Dimitrakopoulos 2016).

Montiel y Dimitrakopoulos (2015) presentan un modelo de optimización de un complejo minero con múltiples pits considerando incertidumbre geológica mediante simulaciones estocásticas. La función objetivo del modelo se encarga de maximizar el VPN mientras que minimiza las desviaciones de los objetivos a lo largo de los periodos y de los distintos escenarios. En el estudio consideran distintos destinos de procesamiento para lo que toman en cuenta algunas propiedades metalúrgicas que no se comentan, y que, para cada destino, estas propiedades deben estar dentro de un rango. El no cumplimiento con estos rangos es lo que se intenta minimizar en la función objetivo a través del costo de penalización. Por otro lado, cada destino de procesamiento cuenta con sus propios valores de capacidades, costos de operación, recuperación, rangos operacionales de las propiedades metalúrgicas y especificaciones de productividad. El modelo propuesto puede variar el modo de procesamiento, por ejemplo, pasar de una molienda gruesa a fina y viceversa tomando además en cuenta una cierta recuperación, costos y capacidad para cada una. Para resolver el modelo se emplea *simulated annealing*. Los autores emplean el modelo en un caso de estudio de un complejo minero que cuenta con dos pits y que produce cobre. A modo de comparación se generan resultados de un enfoque determinista y del modelo. El modelo para ciertos periodos modifica el modo de molienda, generando de esa forma un aumento del 5 % del VPN y una disminución del promedio de las desviaciones de las capacidades de un 18 % a 1 % y de un 22 % a un 3 % para los molinos pequeño y grande respectivamente.

Coward y Dowd (2015) usan el enfoque de evaluación de proyectos basada en escenarios (SBPE en inglés) que es un método estocástico para modelar la cadena de valor de un negocio minero. Los autores lo emplean en un caso de estudio de un pórfido polimetálico, cuya planta presenta diferentes caminos de procesamiento. Se genera un caso de estimación y 100 simulaciones y se calcula mediante NSR (*Net Smelter Return*) con el objetivo de ver que bloques corresponden a lastre y mineral. Las curvas de valor muestran una variación del 70 %

en el VPN entre los percentiles 10 y 90 con respecto al caso base. El modelo usa información de curvas de recuperación dependiendo de las diferentes rutas de procesamiento, y no usa directamente información geometalúrgica.

Kumar y Dimitrakopoulos (2019) comentan la importancia de incluir variables geometalúrgicas en el proceso de planificación minera. Los autores integran parámetros de *SAG power index* (SPI) y *bond work index* (BWI) en una función objetivo de dos etapas, que maximiza el valor generado por el proyecto mientras que minimiza las desviaciones de capacidad, mezcla, etc. Por su naturaleza, estas variables no son aditivas y para incluir estas variables en el proceso de optimización, los autores primero buscan la proporción de material blando y duro que maximiza la recuperación y productividad, y a esto lo llaman target geometalúrgico y en relación a este valor, se definen penalizaciones por desviación. Esto lo aplican a un caso de estudio de una mina de cobre-oro. Los resultados muestran grandes diferencias entre las simulaciones de ley y valores SPI y BWI en comparación al modelo estimado, y que la optimización estocástica utiliza de una mejor manera los molinos y chancadores. Por otro lado, el VPN aumenta en un 19.3% en comparación a la metodología convencional, aumenta el cobre, oro, hierro y molibdeno recuperado. Estas diferencias se generan por la incorporación de la incertidumbre y variabilidad de leyes, tipo de material, variables geometalúrgicas, entre otras.

En Morales et al. (2019) se genera el agendamiento a largo plazo de un depósito porfirico usando un modelo de bloques e información geometalúrgica, para ver el impacto que tiene esta última en el proceso de planificación. La metodología propuesta se divide en dos etapas. En primer lugar, se generan pits finales para todos los casos y luego mediante confiabilidad se escoge un pit final y, en segundo lugar, se usa un modelo estocástico de agendamiento directo de bloques, cuya función objetivo para cada caso maximiza el valor descontado del proyecto y minimiza el costo total de desviación con respecto al objetivo de producción. Las variables geológicas usadas son ley de Cu y Mo, mientras que las variables geometalúrgicas corresponden a recuperación de Cu, y rendimiento de la conminución (en toneladas por hora, que se asemeja a la dureza del material). Para cada una de estas variables se generan 50 simulaciones y se analizan cuatro casos (el primero contempla el promedio de las simulaciones de cada variable, Tipo-E, mientras que en los otros tres se va agregando información de las simulaciones).

Al comparar los cuatro casos, se aprecia que los tres que usan variables simuladas presentan mayores VPN, tonelaje de mineral, tonelaje de cobre y de molibdeno, pero en tonelaje de roca solo el caso cuatro (que considera todas las variables simuladas simultáneamente) presenta el menor tonelaje disponible (que puede estar relacionado a una menor cantidad de lastre). El pit obtenido con el modelo Tipo-E presenta menor tonelaje y valor y esto se debe al suavizamiento de las leyes de cobre. Al momento de generar los pits, los tres esquemas presentan un pit muy similar en la parte oeste, pero no tanto en la parte este (donde está la mayor variabilidad) y los tres presentaron pits más grandes en comparación al Tipo-E. Con respecto al agendamiento, el modelo Tipo-E presenta el menor VPN y con el mayor riesgo, y la menor media de tonelaje. El caso dos, que contempla las simulaciones de la ley de cobre y molibdeno, presenta en promedio un mayor tonelaje y un VPN levemente superior (2.5% mayor), y menor riesgo (en comparación al Tipo-E) pero cabe destacar que el caso cuatro, que contempla todas las variables simuladas, presenta un 68.5% menos de riesgo y un VPN

9.4% mayor al Tipo-E. También ocurre una variación en la secuencia de extracción al incluir más información. El gráfico de tonelaje y VPN, con barras de error, del caso uno y cuatro se puede ver en la Figura 2.15. Esto último indica que al incluir más información se puede aumentar el valor y reducir el riesgo de un proyecto.

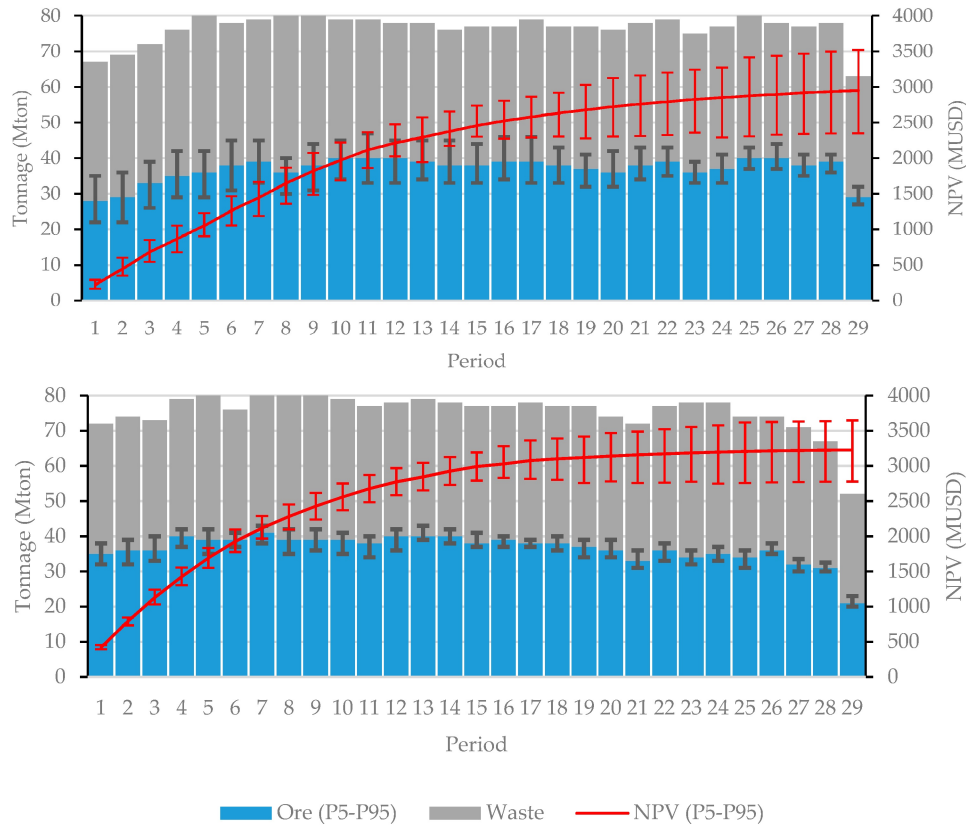


Figura 2.15: Tonelaje y VPN del caso 1 (arriba) y caso 4 (abajo) (Morales et al., 2019).

En Alves Campos et al. (2021) se propone una metodología en la que se considera una recuperación metalúrgica de alimentación a planta, porque de otra forma, el resultado es sesgado. En primer lugar, con la ayuda de una curva de regresión de ley de alimentación y recuperación de cobre de una mina en Brasil se generan dos casos de ejemplo, el enfoque tradicional y “volumen de alimentación”, en el que el segundo reporta una mejor recuperación porque considera a todos los bloques juntos (considera mezcla) y no por separado. En segundo lugar, de un modelo de bloques en 2D de lo que consideran 40 bloques (pensando en una planificación a corto plazo) y tomando los mismos enfoques los autores observan que la recuperación geometalúrgica global es sensible al usar diferentes modelos de regresión lo que puede conducir a resultados erróneos. Cabe destacar, que en estos dos enfoques la extracción de los bloques es la misma. Finalmente, en un tercer análisis con los mismos 40 bloques, se considera litología donde 29 son sulfuros y 11 son óxidos. El enfoque tradicional ignora como se mezclan ambas litologías en la planta y los considera todos como iguales. El enfoque de “volumen de alimentación” considera diferentes litologías obteniendo una ley 1.17% mayor y un VPN 28% superior al caso anterior, pero usa el mismo agendamiento en el que manda a planta los bloques con mayores leyes primero. Proponen un enfoque más, que considera distintas litologías, pero a diferencia del caso anterior en este el agendamiento cambia el orden de nueve bloques debido a que se contempla maximizar la recuperación global de mezcla,



obteniendo un 1.64 % de recuperación global mayor y 39 % más VPN que el caso tradicional. Este estudio resalta la importancia de considerar que este tipo de variables no son aditivas. Los autores resaltan que los resultados obtenidos se basan en el ejemplo escogido y que cada empresa debe de evaluar sus propias características porque el impacto puede ser menor o mayor al resultado obtenido. Por ende, se recomienda en todo momento realizar los ensayos geometalúrgicos necesarios para encontrar la mejor relación posible entre la recuperación y variables primarias.

## 2.6. Discusión

Como se menciona en la sección 2.3, el agendamiento de corto plazo presenta diversos desafíos para poder cumplir con el agendamiento de largo plazo y uno de esos esta relacionado al agendamiento de las formas operacionales. Por otro lado, estos planes suelen contener incertidumbre que no se suele considerar. Es por eso, que en esta tesis se abordará este problema pero considerando incertidumbre geológica. Se estudiará la generación de distintos planes mineros, con sus respectivos espacios operacionales, para distintos escenarios y nivel de información. Aparte, se estudia la generación de espacios operacionales con su respectivo plan de producción utilizando curvas de recuperación metalúrgicas para distintos destinos.

Se observa que son pocos los estudios que incluyen variables geometalúrgicas asociadas a planificación minera, y menos aún los estudios que relacionan geología con planificación. En esta última parte existe una gran brecha. A modo de simplificación, distintos estudios consideran que durante el proceso los bloques no tienen ninguna interacción entre ellos (como si se procesarán de forma individual) que pueda afectar su respuesta en el proceso (ya sea en la planta flotación, molienda, entre otros). Pero eso en la operación no existe porque geológicamente si lo afecta de alguna u otra forma, como se comenta en la sección 2.4.1.

En estudios como los de Del Castillo y Dimitrakopoulos (2016) o Nelis et al., (2021b) se utilizan recuperaciones no lineales, lo que permite generar planes mas realistas. De los dos estudios mencionados, el segundo lo hace en el corto plazo. En Nelis et al., (2021b) no solo se modifican las formas operativas al considerar recuperación variable, y efectos de mezcla, sino que también mejora el negocio a diferencia de tener una recuperación constante. Al igual que los estudios comentados anteriormente, en Alves Campos et al. (2021) también se consideran efectos de mezcla obteniendo mejores resultados en comparación a la metodología tradicional.

Por otro lado, en lo que respecta a la planificación minera en el corto plazo y formas operativas, son pocos los estudios que consideren la incertidumbre geológica. En Kumral (2015) se utilizan diez escenarios geológicos pero no se comenta nada de algún escenario en particular ni como quedan las formas operativas en cada uno. Por otro lado, en Tabesh y Askari-Nasab (2019) se generan clusters utilizando distintas realizaciones de los datos usando la metodología de *possible worlds* pero no se comenta como queda la producción de los escenarios. Algo similar ocurre en Rahmanpour y Osanloo (2016), en donde utilizan distintos escenarios geológicos mejorando la producción debido a un aumento en la tasa de extracción, pero por otro lado, no se dice nada sobre la formación de clusters. En Nelis y Morales (2021a) si bien se logra formar cluster con su respectivo agendamiento en el corto plazo, este no considera incertidumbre geológica.

# Capítulo 3

## Modelo de Optimización

En esta sección se comenta cómo funciona el modelo de optimización, su función objetivo y sus respectivas restricciones. Esto, en gran parte, está basado en el artículo de Nelis y Morales, 2021a.

El modelo presentado selecciona que SMUs (también llamados bloques desde ahora) componen un determinado cluster y le asigna uno de los destinos disponibles a este último. La extracción de los clusters puede pasar de un periodo a otro y no debe superar los límites permitidos de capacidad de planta y de extracción. En lo que respecta a la formación de estos clusters, el modelo considera un número mínimo y máximo de SMUs que los pueden formar y al mismo tiempo, un número máximo de clusters que se pueden generar para un determinado agendamiento.

El objetivo es generar clusters tal que se pueda maximizar su valor a través de un agendamiento, para lo que se estudia el valor de cada cluster y que todos los bloques de un mismo cluster vayan al mismo destino. Por otro lado, para efectos de este estudio, se considera que un determinado cluster debe ser extraído en su totalidad dentro de un mismo periodo.

Para llevar a cabo el agendamiento, en el input se consideran bloques candidatos a ser *bloques representantes*, que como su nombre dice, representan a un determinado cluster y que unirán a él una cierta cantidad de bloques. Esto se puede ver ilustrativamente en la Figura 3.1, donde en la figura de la izquierda se ven de color amarillo los ocho bloques candidatos, luego en la figura del medio se ve que el modelo escogió cinco representantes escogidos y finalmente genera cinco clusters. El modelo no está obligado a generar tantos clusters como candidatos hayan, por ende, los candidatos que no son escogidos pasan a ser bloques normales (o comunes) mientras que los candidatos seleccionados pasan a ser bloques representantes. Un ejemplo de esto se ve en la Figura 3.2 con uno de los resultados del estudio, en donde en los bloques representantes están marcados como cuadrados de color rojo mientras que los que se quedaron como candidatos con una  $X$  en rojo y las líneas rojas delimitan los clusters.

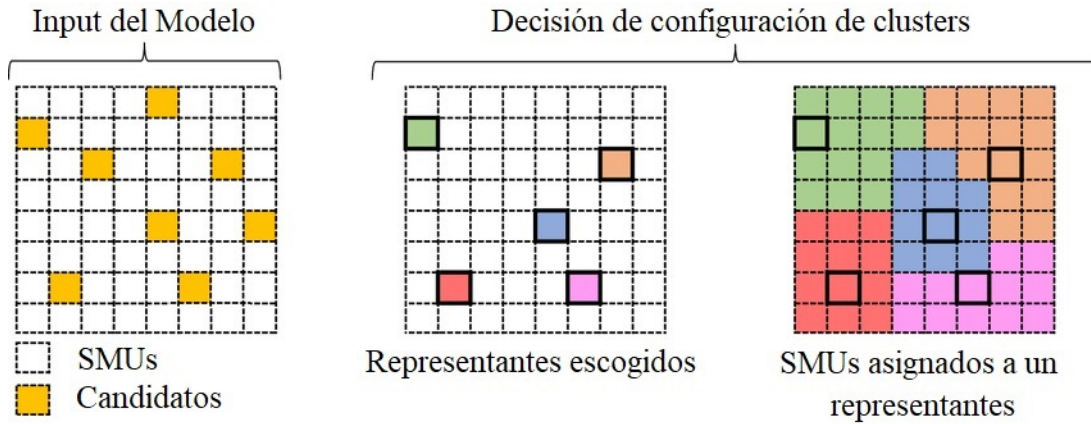


Figura 3.1: Definición de cluster en función a un representante basado en el modelo de optimización. Los colores representan distintos clusters y su bloque representante (Modificado de Nelis y Morales, 2021a).






Figura 3.2: Ejemplo de bloques representantes, candidatos no seleccionados y clusters.

La forma y conectividad de los clusters está controlada por arcos de precedencia, que pueden ser de forma diagonal o cuadrada, van dirigidos desde un cierto bloque a un representante. Estos arcos se pueden apreciar en la Figura 3.3 donde cada cuadrado equivale a un bloque. En la izquierda, se observa un bloque arbitrario (en color negro) y 3 bloques representantes (en colores rojo, amarillo y verde). Del mismo color al bloque representante, se aprecia un set de antecesores y el modelo decide cual de estas precedencia fuerza para asignar el SMU negro a un representante. Por otro lado, en la parte derecha de la Figura 3.3 se muestran geometrías de clusters generados inducidas por los arcos de precedencia. De esta forma, se asegura que los clusters generados son válidos (es decir, que los bloques que lo componen están conectados) y de la misma forma se puede ir controlando sus formas.

Otro parámetro importante del modelo de optimización es que aparte de utilizar los arcos de precedencia antes descritos (que en resumen, se basan en que los bloques que componen un cluster tengan igual destino), existen otros arcos de precedencia que hacen que se siga un orden periodo a periodo. Estos últimos, pueden ser del tipo "Tree" (Árbol) o un archivo.



(a) Tipo de precedencia diagonal



(b) Tipo de precedencia cuadrada

Figura 3.3: Ejemplo de arcos de precedencia entre un SMU (negro) hacia tres representantes (rojo, verde y amarillo) (izquierda) y formas de clusters generadas (derecha) (Modificado de Nelis y Morales, 2021a).

En esta tesis, se usa el tipo “*Tree*” que determina el orden en el que se extraen los representantes en función a la distancia entre ellos. Desde un bloque representante, pasa a otro y así sucesivamente formando ramas, que hace que se parezca a un árbol. Cabe destacar, que esto se hace desde el representante más cercano a la rampa. Luego, a través de los arcos tipo cuadrado, se define la forma y los bloques que pertenecen a un determinado cluster en función a las capacidades de procesamiento en alguna de las plantas y de mina. Con respecto al valor económico de un cluster, corresponde a la suma de valor (asociado al destino del cluster) de los bloques que lo constituyen y depende de la ley de mineral, recuperación y destino.

Al momento de ejecutar el modelo, lo primero que hace, es ver si para un cierto máximo radio de búsqueda dado en los parámetros de entrada, puede asignar a todos los bloques a un cierto representante. Un ejemplo de esto se puede ver en la Figura 3.4 donde se aprecia de color amarillo los bloques representantes y de morado los SMUs. Se observa que hay círculos concéntricos cuyo centro son los bloques representantes. Los bloques que solo caen dentro de un círculo tienen que ir unidos al representante respectivo y en el caso de los que se encuentran en más de uno, el modelo debe ver a cual los une. Los clusters no pueden traspasar de un banco a otro. En caso de que no pueda, manda un aviso y el modelo deja de correr. En la Tabla 3.1 se pueden ver las variables usadas.

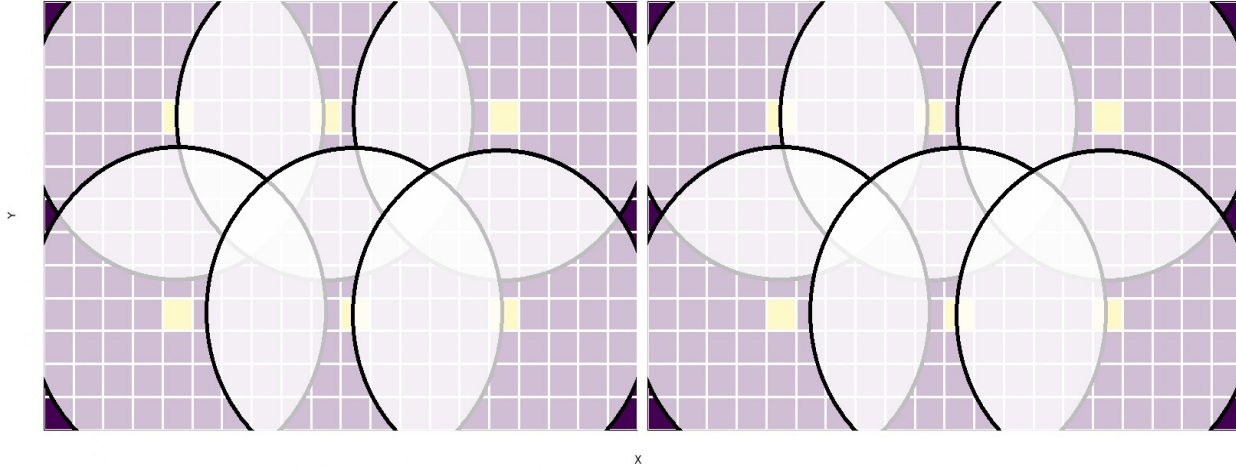


Figura 3.4: Ejemplo de radios de búsqueda del modelo de optimización.

Tabla 3.1: Descripción de parámetros, sets e índices usados

<b>Sets e Índices</b>	
SMU y sets de SMU	$b, i, j \in B$
Periodos y set de periodos	$t, p \in T$
Representantes y set de representantes	$r \in R \subseteq B$
Destino y set de posibles destinos	$d \in D$
Recursos y set de recursos operacionales y procesamiento	$c \in C$
Set de arcos de precedencia dirigidos a representantes SMU $r \in R$	$P_r \subseteq B \times B$
Set de arcos de precedencia entre representantes SMUs	$P_R \subseteq R \times R$
<b>Parámetros</b>	
Ingresos obtenidos si el bloque $b$ es asignado al representante $r$ y enviado al destino $d$ en el periodo $t$	$\nu_{btdr}$
Cantidad de recursos $c$ consumidos en la extracción del bloque $b$	$\alpha_{cd}$
Límite superior de recursos $c$ disponibles	$u_c$
Cantidad de recursos $c$ consumidos en el procesamiento del bloque $b$ en el destino $d$	$\beta_{cbd}$
Límite superior de recursos $c$ disponibles en el destino $d$	$u_{cd}$
Cantidad mínima de bloques asociados a un representante $r$	$l_r$
Cantidad máxima de bloques asociados a un representante $r$	$u_r$
Máximo número de representantes usados para el agendamiento	$N_{max\_cluster}$
Tasa de descuento	$rate$

A continuación se muestra la función objetivo del modelo con sus respectivas restricciones.

### Función objetivo del modelo de optimización

La función objetivo corresponde a la mostrada en la siguiente ecuación.

$$\max \sum_{b \in B} \sum_{t \in T} \sum_{d \in D} \sum_{r \in R} v_{btdr} * \frac{x_{btdr}}{(1 + rate)^t} \quad (3.1)$$

En la Ecuación 3.1,  $x_{btdr}$  representa una variable de decisión que se detalle a continuación.

$$x_{btdr} = \begin{cases} 1 & \text{si el SMU } b \text{ tiene destino } d \text{ en el periodo } t \text{ asignado al representante SMU } r \\ 0 & \text{de lo contrario} \end{cases} \quad (3.2)$$

### Restricciones

1. Restricción de capacidad mina:

$$\sum_{b \in B} \sum_{d \in D} \sum_{r \in R} \alpha_{cd} x_{btdr} \leq u_c \quad \forall t \in T, c \in C \quad (3.3)$$

La Ecuación 3.3 representa la capacidad mina, que limita el tonelaje total extraído por periodo. Solo se impone un límite superior en el consumo total de recursos  $c \in C$  empleados en el proceso de extracción.

2. Restricción de capacidad de procesamiento:

$$\sum_{b \in B} \sum_{r \in R} \beta_{cbd} x_{btdr} \leq u_{cd} \quad \forall t \in T, c \in C, d \in D \quad (3.4)$$

La Ecuación 3.4 representa la capacidad que cada planta puede procesar en un periodo. Impone un límite superior en la cantidad de recursos  $c \in C$  procesado en cada destino  $d \in D$ .

3. Restricción de unicidad:

$$\sum_{r \in R} \sum_{d \in D} \sum_{t \in T} x_{btdr} = 1 \quad \forall b \in B \quad (3.5)$$

La Ecuación 3.5 representa la unicidad e impone que todos los bloques solo se extraen una sola vez.

4. Restricción de tamaño de los clusters:

$$\sum_{t \in T} \sum_{d \in D} x_{rtdr} l_r \leq \sum_{b \in B} \sum_{t \in T} \sum_{d \in D} x_{btdr} \leq \sum_{t \in T} \sum_{d \in D} x_{rtdr} u_r \quad \forall r \in R \quad (3.6)$$

La Ecuación 3.6 impone un límite superior e inferior para el tamaño de cada clustes, definidos como el número de SMUs  $b \in B$  asociados a cada representante SMU  $r \in R$ .

Es necesario resaltar que cada limite presenta la variable  $x_{rt dr}$ . Esta variable es 1 si SMU  $r$  es asignado a un representante  $r$ . Como el modelo de optimización no está obligado a usar todos los representantes asignados, esta variable sirve como indicador de si el modelo escoge dicho representante. En caso de que el representante  $r$  sea escogido, se tiene que  $x_{rt dr} = 1$  y ambos limites están activos, en caso de que no lo escoja ( $x_{rt dr} = 0$ ), ambos limites se anulan.

5. Restricción de número de clusters:

$$\sum_{t \in T} \sum_{d \in D} \sum_{r \in R} x_{rt dr} \leq N_{max\_cluster} \quad (3.7)$$

La Ecuación 3.7 impone un límite total de clusters que se pueden generar. En otras palabras, un límite de representantes que se pueden seleccionar lo que le permite al modelo escoger entre distintos SMUs limitados por  $N_{max\_cluster}$ .

6. Restricción de precedencia de clusters:

$$\sum_{d \in D} x_{jtdj} \leq \sum_{p=1}^t \sum_{d \in D} x_{itdi} \quad \forall (i, j) \in P_R, t \in T \quad (3.8)$$

La Ecuación 3.8 representa la restricción de precedencia e impone un orden de extracción para los distintos bloques representantes. Con esto, se logra mantener un avance de extracción factible partiendo, en este estudio, desde el bloque de la esquina inferior izquierda de cada banco porque es el que está conectado a la rampa.

7. Restricción de forma de clusters:

$$\sum_{t \in T} x_{jtdr} \leq \sum_{t \in T} x_{itdr} \quad \forall (i, j) \in P_r, r \in R, d \in D \quad (3.9)$$

La Ecuación 3.9 representa la restricción de la forma de los clusters e impone una restricción de “destino” para todos los bloques (SMUs) asignados a un cierto representante  $r$ . Por ende, para cada par  $(i, j) \in P_R$ , si el bloque  $i$  es asignado al representante  $r$ , el bloque  $j$  también debe ser asignado al representante  $r$  y deben de compartir el mismo destino.

# Capítulo 4

## Metodología

En esta sección se presenta la metodología empleada en este trabajo de tesis.

1. Para estudiar el efecto que tiene la incertidumbre de los datos se generan distintos escenarios insertando un ruido correspondiente a un valor escogido al azar relacionado a la varianza de los datos del caso base. Esto se muestra en la siguiente ecuación.

$$L + \nu; \nu \in (-\sigma^2, +\sigma^2) \quad (4.1)$$

Donde  $L$  corresponde a la ley de caso base,  $\nu$  al valor aleatorio generado y  $\sigma^2$  que corresponde a la varianza de los datos. Otra restricción implementada consiste en que la media de cada uno de estos casos este en un rango de  $\pm 0.2$  con respecto a la media del caso base. Esto lo deben cumplir todos los casos y los tipos de mineralización existentes. En la siguiente ecuación se puede ver esto, donde  $P_C$  corresponde a la media de cada uno de los escenarios generados y  $P_{CB}$  corresponde a la media del caso base.

$$P_C \in (P_{CB} - 0,2, P_{CB} + 0,2) \quad (4.2)$$

2. Una vez listos los escenarios, se calcula el mejor destino a nivel de bloque de todos utilizando las ecuaciones 2.1 y 2.2, mencionada en la sección 2.1.1, considerando tres posibles destinos (planta de óxidos, planta de sulfuros y botadero) en donde cada uno cuenta con sus respectivos costos de procesamiento, costos de venta y recuperación metalúrgica.
3. Se emplea el modelo de optimización de agendamiento en el corto plazo que se encuentra descrito en la sección 3 para generar un agendamiento a nivel de bloque (ANB) que se usa para comparar con los otros resultados (este no utiliza clusters).
4. En esta parte se generan los clusters a través de tres casos de estudio principales para el agendamiento de corto plazo de cuatro meses. Para cada uno, cuyas descripciones se pueden ver a continuación, se generan distintas pruebas con tres radios de búsqueda diferentes en cada una. Cada prueba difiere de la otra en la cantidad, ubicación de los bloques candidatos a ser bloques representantes y/o el número mínimo de bloques que componen un cluster. Para los dos primeros casos, los candidatos se asignan estudiando



el mejor destino bloque a bloque del caso base considerando una distribución relativamente uniforme de estos o ubicándolos en zonas de mayor variabilidad, mientras que para el tercero es distinto. Se realizan diez pruebas para los dos primeros casos y seis pruebas para el tercero. Como resultado se obtienen distintas figuras (distribución, destino y periodo de extracción de los clusters) y un archivo que resume la información de las figuras y además muestra el valor económico. Los casos de estudio que se emplean en la tesis son los siguientes:

- a) Determinista (DET): Luego de usar el modelo de optimización, se hace uso de los clusters generados (es decir, el destino y periodo de extracción de los bloques) del caso base en los otros escenarios. El objetivo de esto es considerar que cada escenario se comporta de la misma forma que el caso base.
  - b) Conocimiento Parcial (CPAR): Luego de usar el modelo de optimización, se generan distintos clusters para cada uno de los escenarios. En este caso se considera que se tiene un conocimiento parcial de la realidad, dado que se toman los mismos representantes del caso base, pero los clusters de cada escenario tienen distinto destino y están formados por distintos bloques.
  - c) Conocimiento Perfecto (CP): Se genera una malla de bloques candidatos en la que cada uno se encuentra separado a una distancia de tres bloques en la dirección X e Y. Como resultado del modelo de optimización, se tiene no solo distintos clusters (en forma y cantidad de bloques) y destino, sino que además distintos representantes escogidos por cada escenario.
5. En los pasos 3 y 4, se utiliza una recuperación constante para cada planta, por eso, en este paso se aplica una curva de recuperación que dependerá de la ley de alimentación. Esta curva es diferente para cada tipo de planta. Esto se aplica para todas las pruebas pero solo usando el radio de búsqueda que tuvo el mayor promedio de VPN con recuperación constante, y solo para los casos CPAR y CP.
  6. Finalmente, se calcula el VPN para un periodo de 4 meses y se hacen análisis de sensibilidad entre los distintos resultados obtenidos para cada uno de los casos principales, y se cruza la información obtenida entre estos para ver las diferencias.

En la Figura 4.1 se puede ver toda la metodología empleada en este trabajo resumida en un esquema.

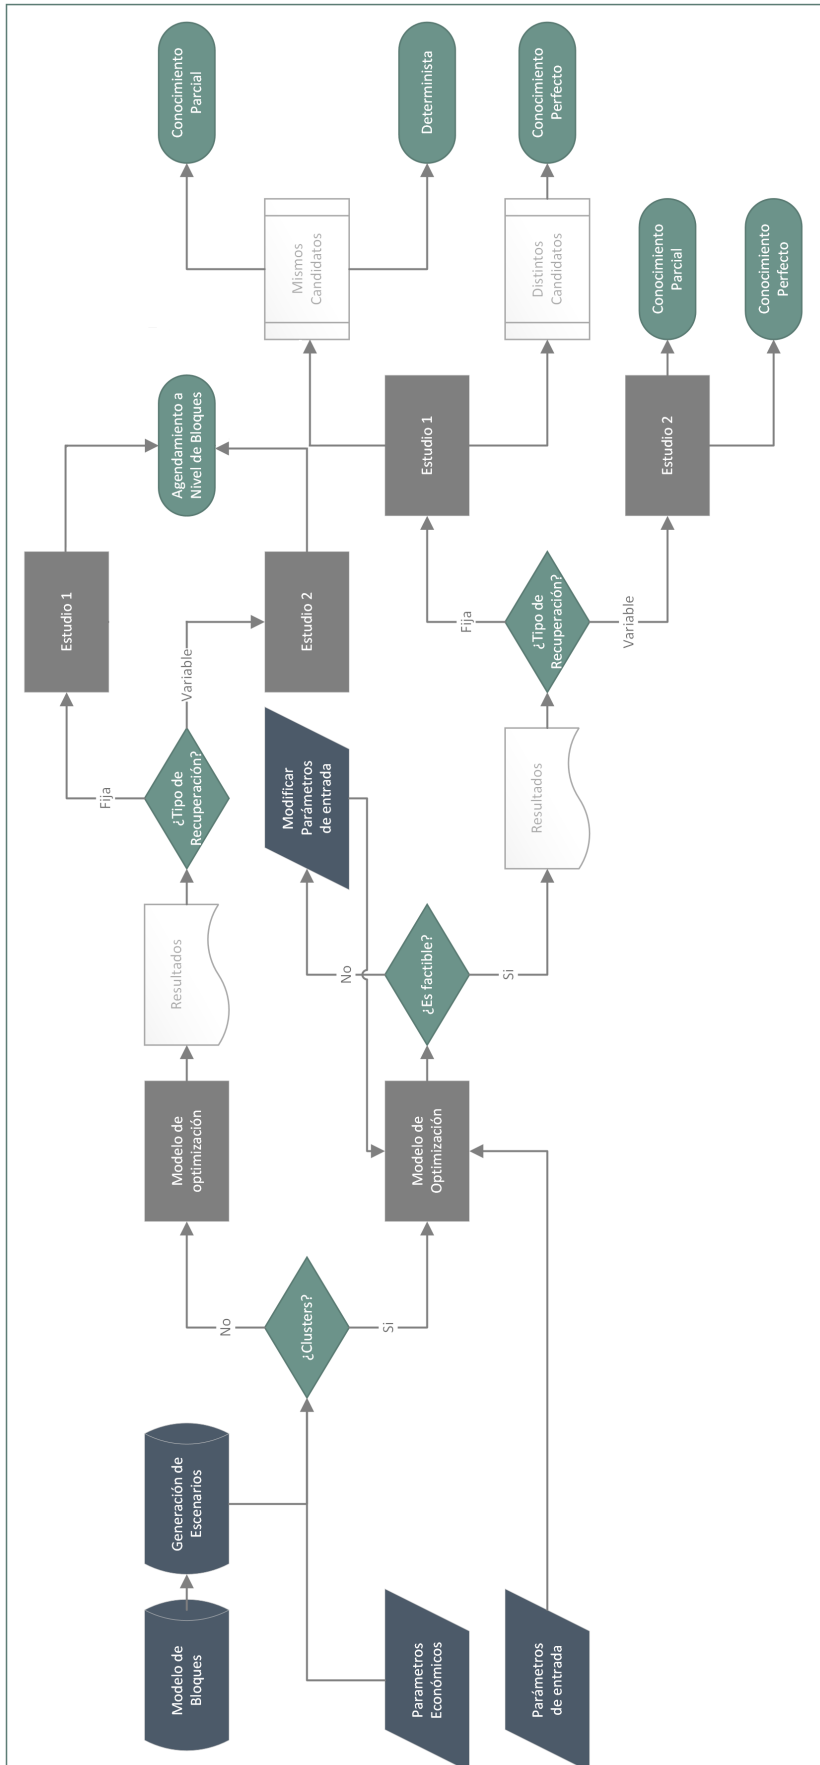


Figura 4.1: Diagrama de flujo de la metodología.

# Capítulo 5

## Experiencias Numéricas

En esta sección se presentan los principales resultados de este trabajo con algunos comentarios.

### 5.1. Caso de Estudio

El modelo de bloques usado en esta tesis está compuesto por un total de 520 bloques, con dimensiones de  $5 \times 5 \times 10 \text{ m}^3$  y distribuidos en dos bancos. Cada bloque cuenta con una ley de cobre oxidado y sulfurado. Su distribución en planta se puede en la Figura 5.1 y su estadística básica en la Tabla 5.1.




Figura 5.1: Distribución de las leyes de cobre oxidado (arriba) y sulfurado (abajo) del Caso 0.

Tabla 5.1: Estadística básica de la ley de cobre para ambas mineralizaciones del Caso 0.

	Cobre Oxidado	Cobre Sulfurado
Media [%]	0.51	0.71
Desviación Estándar	0.35	0.49
Varianza	0.12	0.24
Mínimo [%]	0.00	0.00
1er cuartil [%]	0.22	0.33
Mediana [%]	0.43	0.59
3er cuartil [%]	0.75	1.07
Máximo [%]	1.63	2.46

En la Figura 5.1, se aprecian los dos bancos antes mencionados, donde los dos de arriba corresponden a ley de cobre oxidado y los dos de abajo a ley de cobre sulfurado. A la izquierda se aprecia el banco 0 en donde las leyes de ambas mineralizaciones se encuentran más mezcladas, mientras que a la derecha, esta el banco 1 en el que se ve una mayor separación de las leyes altas de cada mineralización. El banco 0 esta esta ubicado en  $Z=0$  mientras que el banco 1 en  $Z=10$ . Para estudiar el efecto de incertidumbre, se generan 20 escenarios de ambas leyes haciendo uso de la Ecuación 4.1 y la restricción del promedio como muestra la Ecuación 4.2. Algunos escenarios generados se aprecian en la Figura 5.2 y 5.3.




Figura 5.2: Distribución de las leyes de cobre sulfurado de los escenarios 8 (arriba) y 15 (abajo).





Figura 5.3: Distribución de las leyes de cobre oxidado de los escenarios 8 (arriba) y 15 (abajo).

Los escenarios se generaron a través de Python 3. La media y varianza de ambos tipos de mineralización de cobre tanto para el caso base como para los escenarios generados se pueden ver en las Figura 5.4, 5.5, 5.6 y 5.7. Se puede apreciar que tanto las medias y varianzas para ambos tipos de mineralización son similares.

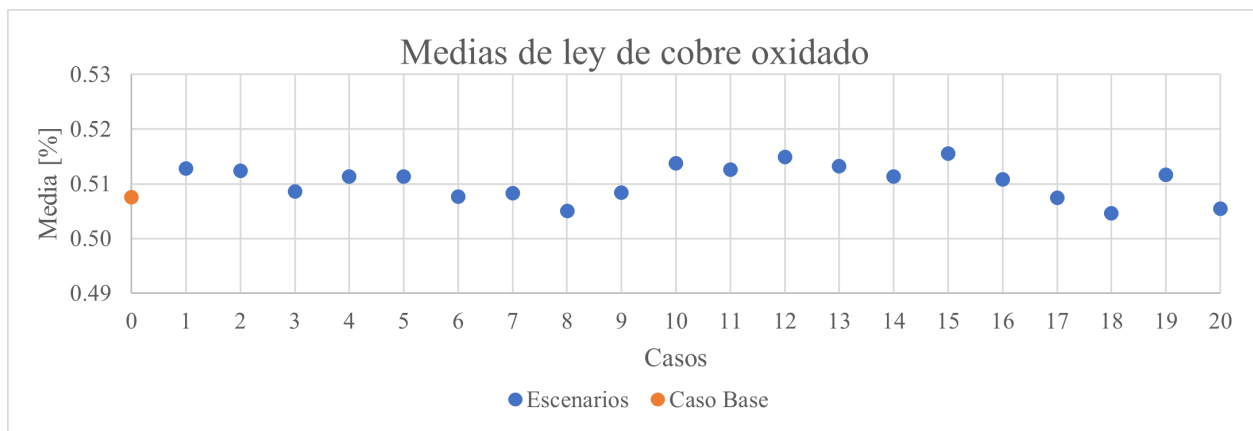


Figura 5.4: Gráfico de media de ley de cobre oxidado del caso base y escenarios.




Figura 5.5: Gráfico de media de ley de cobre sulfurado del caso base y escenarios.

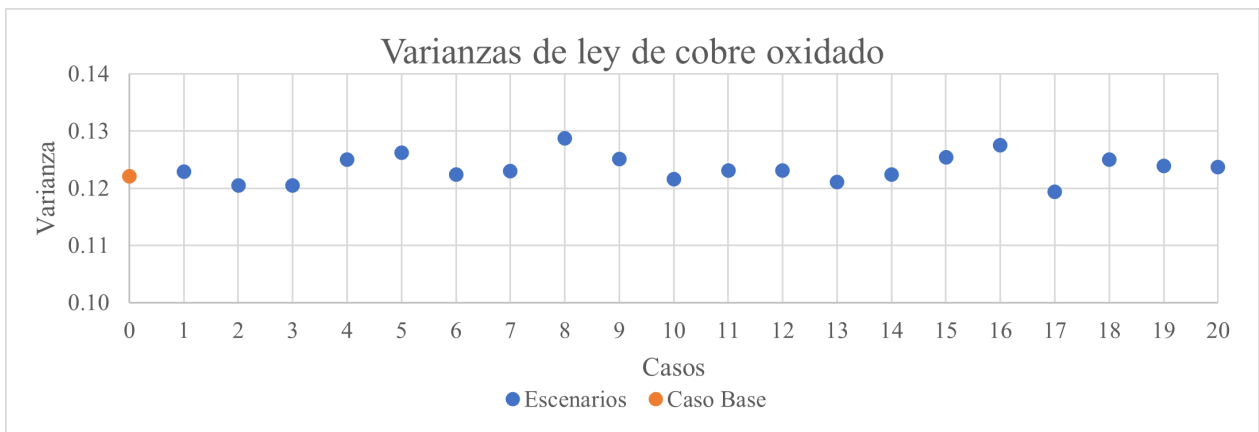


Figura 5.6: Gráfico de varianza de ley de cobre oxidado del caso base y escenarios.




Figura 5.7: Gráfico de varianza de ley de cobre sulfurado del caso base y escenarios.

### 5.1.1. Valorización

Para conocer el mejor destino de los bloques, se utilizan los parámetros económicos de la Tabla 5.2 (Nelis y Morales, 2021a) en las ecuaciones 2.1 y 2.2. En la Figura 5.8 se puede ver

un mapa del mejor destino a nivel de bloque del Caso Base con los 3 destinos posibles.

Tabla 5.2: Parámetros económicos.

Parámetro	
Costo Mina [USD/ton]	1.5
Costo Planta Óxidos [USD/ton]	5.0
Costo Planta Sulfuros [USD/ton]	9.0
Precio Cobre [USD/lb]	2.0
Costo Venta Óxidos [USD/lb]	0.2
Costo Venta Sulfuros [USD/lb]	0.3
Recuperación Óxidos [%]	75.0
Recuperación Sulfuros [%]	85.0
Capacidad Mina [ton/mes]	135,000.0
Capacidad Planta Óxidos [ton/mes]	67,500.0
Capacidad Planta Sulfuros [ton/mes]	67,500.0
Tasa de descuento mensual [%]	1.0




Figura 5.8: Mejor destino por bloque del Caso Base.

Se puede apreciar que en el banco 0 existe una mayor variabilidad con respecto al destino que en el banco 1, donde se ve que los destinos a la planta de sulfuros o óxidos se encuentran relativamente bien separados. Todos los resultados de DET y CPAR se obtuvieron con un pc HP Pavilion Gaming con Core i5 de 9na generación y 8 GB de RAM, con el que el tiempo de ejecución nunca supero los 50 minutos. Mientras que los resultados de CP, se generaron en un servidor de la Facultad de Ciencias Físicas y Matemáticas de la Universidad de Chile con un procesador Intel(R) Xeon(R) CPU E5-2620 v3 2.40 GHz y 128 GB de RAM. Los tiempos de ejecución fueron muy variados, teniendo tiempos desde los 25 minutos hasta las 32 horas (prueba 16 y radio 10). Para efectos de la extracción en el caso de estudio, esta parte desde la esquina inferior izquierda de cada banco y los arcos de precedencia a usar son cuadrados.

## 5.2. Agendamiento a Nivel de Bloque

Se realiza un agendamiento a nivel de bloque de todos los escenarios para luego utilizarlo a modo de comparación con el resto de los resultados. En la Figura 5.9 se observa un gráfico de VPN de todos los escenarios mientras que en la Figura 5.10 un gráfico de barras con la utilización promedio por periodo de los distintos destinos disponibles.




Figura 5.9: VPN del agendamiento a nivel de Bloque.




Figura 5.10: Promedio de utilización de los distintos destinos por periodo para todos los escenarios del agendamiento a nivel de bloque.



En la Figura 5.9 los escenarios están ordenados de forma ascendente con respecto a su VPN, siendo en ese caso el escenario 0 el de menor valor y el escenario 1 el de mayor valor.

Como se aprecia de la Figura 5.10, durante los primeros 2 periodos ambas plantas se usan al 100% mientras que en el tercer periodo no. Los bloques que se extraen en el cuarto periodo son bloques con valores negativos y se observa que algunos van a planta de sulfuro y óxidos por el simple motivo de que es más rentable que llevarlos al botadero. Cabe recordar que esos bloques no se extraen en el tercer periodo porque la función objetivo (Ecuación 3.1) maximiza el VPN. Por otro lado, el VPN promedio de este agendamiento es de 6.67 MUSD.

En lo que respecta a la secuencia de extracción, en la Figura 5.11 se pueden ver dos ejemplos de distintos escenarios de ambos bancos. Los periodos 1, 2, 3 y 4 están representados por los colores morado, azul, verde y amarillo respectivamente. Se puede apreciar que se tienen bloques que se extraen en un periodo  $t$  rodeados por bloques cuyo periodo de extracción es en  $t + 1$  e inclusive  $t + 2$  lo que lo hace imposible de llevar a cabo operacionalmente.




Figura 5.11: Periodo de extracción de agendamiento por bloques para dos escenarios.

### 5.3. Casos Determinista y Conocimiento Parcial

Para llevar a cabo el estudio de los casos deterministas (DET) y conocimiento parcial (CPAR), se generan 10 pruebas diferentes. La descripción de cada una se puede encontrar en el Capítulo 4.

Los clusters se componen como máximo por 50 bloques en todas las pruebas, pero el mínimo de bloques varia para estudiar el impacto de generar clusters más pequeños en las zonas de mayor variabilidad. El número máximo de bloques que pueden formar un cluster, limita a tener como mínimo un total de 11 clusters lo que significa, que se necesitan como mínimo 11 bloques candidatos a ser representantes.

Los radios de búsqueda son tres para cada prueba. Para la prueba 1 (P1) se usan los radio 7, 10 y 12, mientras que para el resto de las pruebas, se usan los radios 6, 7 y 10. El radio 12 de la prueba 1 es adicional y sus resultados se pueden encontrar en el capítulo de Anexos A. En el caso de la prueba 1 se parte del radio 7 porque es el radio mínimo con el que existe una solución, y lo mismo ocurre con el radio 6 para el resto de las pruebas. El máximo de 10 para todas las pruebas se hace con el objetivo de impedir que se busquen bloques muy lejos para un cierto representante. Cabe recordar, como dice en el Capítulo 3, que el modelo lo primero que hace es ver si se pueden asignar todos los bloques por lo menos a un representante en función al radio de búsqueda.

En la Tabla 5.3 se puede ver un resumen de la cantidad de candidatos disponibles, y el número máximo y mínimo de bloques por cluster permitidos en cada prueba. El objetivo de ir aumentando el número de candidatos es para estudiar como van cambiando los resultados en valor y en destino.

Tabla 5.3: Pruebas realizadas para los casos deterministas y conocimiento parcial.

Pruebas	Candidatos			Bloques por cluster	
	Banco 0	Banco 1	Total	Mínimo	Máximo
P1	6	6	12	10	50
P2	6	6	12	10	50
P3	6	6	12	10	50
P4	7	7	14	10	50
P5	9	9	18	10	50
P6	9	9	18	8	50
P7	10	10	20	8	50
P8	10	10	20	10	50
P9	11	10	21	10	50
P10	11	10	21	8	50

En las Figuras 5.12, 5.13 y 5.14 se pueden ver la ubicación de los candidatos en color amarillo para las pruebas 2, 5 y 6, y 9 y 10 respectivamente. La distribución de los representantes de las otras pruebas se pueden ver en la sección de Anexos A.




Figura 5.12: Ubicación bloques representantes de Prueba 2.




Figura 5.13: Ubicación bloques representantes de Prueba 5 y 6.




Figura 5.14: Ubicación bloques representantes de Prueba 9 y 10.

Las pruebas 5 y 6, 7 y 8, y 9 y 10 comparten los mismos candidatos, pero como muestra la Tabla 5.3 la diferencia entre ellas está en el mínimo de bloques que pueden componer un cluster.

En algunas pruebas, como en la 1, 2, 7, 8, 9 y 10 (Figura A.1, Figura 5.12, Figura A.4 y Figura 5.14) los candidatos se ubican de manera desordenada a semi-desordenada, mientras que en las demás se encuentran más ordenados. Por otro lado, a excepción de las últimas 2 pruebas, ambos bancos tienen la misma cantidad de candidatos. Esto porque se analiza el ingreso aportado por banco, y se observa que los valores del banco 1 siempre están en el mismo rango mientras que los del banco 0 aumentan con el aumento de los representantes. Esto se ve en la Figura 5.15, donde de color rojo se aprecia el caso base y en azul los escenarios generados.

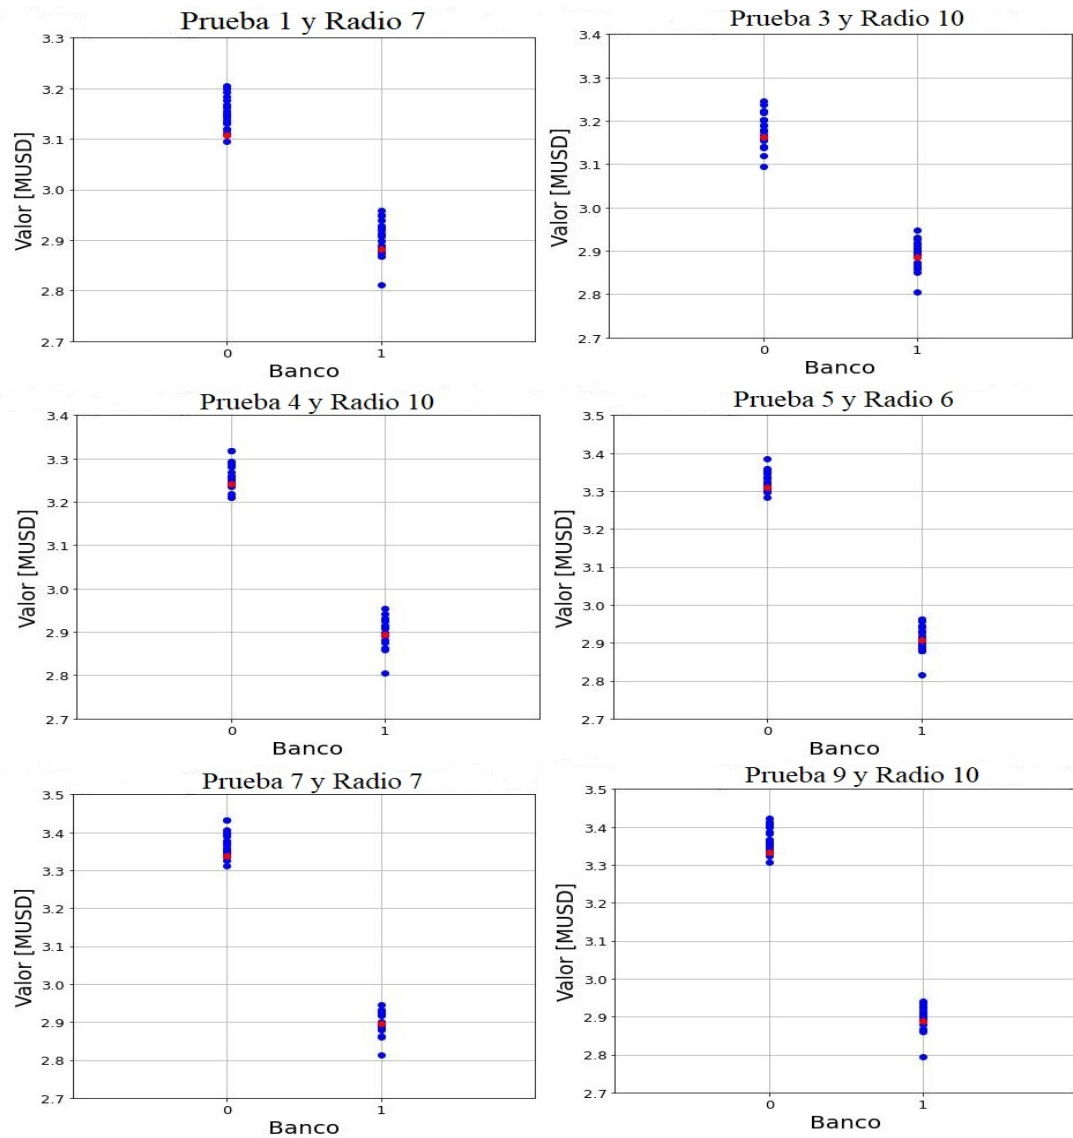


Figura 5.15: Valor de conocimiento parcial (CPAR) por banco para distintas pruebas y radios.

Esto último tiene sentido debido a que, como se muestra en la Figura 5.8, el destino de los bloques está mucho mejor definido en el banco 1 en comparación al banco 0 (en el que el destino está más mezclado). Los ingresos del banco 1 no mejoran ni siquiera aumentando el número de candidatos en la zona de mayor variabilidad de destino (aproximadamente en la coordenada  $Y=30$ ).

### 5.3.1. Valor Económico

En las Figuras 5.16, 5.17, 5.18, 5.19, 5.20 y 5.21 se pueden ver gráficos de VPN en función del radio con algunas pruebas, mientras que los gráficos que contienen todas las pruebas se pueden encontrar en la sección de Anexos A. Se aprecia que, en general, a medida que aumenta el número de representantes también aumenta el VPN del proyecto. Esto se da para ambos tipos de casos, donde además se aprecia que existen 2 grupos principales, de la prueba 1-3 (12 representantes) y de la prueba 5-10 (18-21 representantes). En los distintos gráficos, los escenarios están ordenados de menor a mayor VPN para la prueba que presenta el mayor promedio de VPN y la *R* en la leyenda significa *Representantes*.

La curva superior de todos los gráficos, corresponde a la prueba que tuvo el mayor promedio de VPN mientras que la inferior al de menor promedio. Los colores azul, naranja, gris, amarillo, celeste, verde, azul oscuro y morado corresponden a las pruebas 1, 2, 3, 4, 5, 6, 7 y 9 respectivamente.




Figura 5.16: Gráfico de VPN determinista de algunas pruebas para un radio 6.




Figura 5.17: Gráfico de VPN de CPAR de algunas pruebas para un radio 6.




Figura 5.18: Gráfico de VPN determinista de algunas pruebas para un radio 7.




Figura 5.19: Gráfico de VPN de CPAR de algunas pruebas para un radio 7.




Figura 5.20: Gráfico de VPN determinista de algunas pruebas para un radio 10.




Figura 5.21: Gráfico de VPN de CPAR de algunas pruebas para un radio 10.

En las Tablas 5.4, 5.5, 5.6, 5.7 y 5.8 se pueden ver los resultados de las pruebas 1, 3, 6, 7 y 9 respectivamente. Los resultados de las otras pruebas se pueden encontrar en la sección de Anexos A.

Tabla 5.4: Resumen de resultados de Prueba 1.

	Promedio [MUSD]	Máximo		Mínimo		Diferencia	
		VPN [MUSD]	Escenario	VPN [MUSD]	Escenario	Total [MUSD]	Promedio [MUSD]
R=7 DET	5.90	5.98	7	5.83	4		
R=7 CPAR	5.93	5.98	1	5.86	4	0.56	0.03
R=10 DET	5.95	6.00	7	5.85	4		
R=10 CPAR	5.97	6.04	7	5.92	14	0.43	0.02

Tabla 5.5: Resumen de resultados de Prueba 3.

	Promedio [MUSD]	Máximo		Mínimo		Diferencia	
		VPN [MUSD]	Escenario	VPN [MUSD]	Escenario	Total [MUSD]	Promedio [MUSD]
R=6 DET	5.94	6.00	7	5.88	17		
R=6 CPAR	5.92	5.98	7	5.85	4	-0.31	-0.01
R=7 DET	5.96	6.02	7	5.88	4		
R=7 CPAR	5.95	6.02	7	5.87	4	-0.28	-0.01
R=10 DET	5.95	6.02	7	5.86	4		
R=10 CPAR	5.95	6.02	16	5.87	4	-0.09	<-0.01

Tabla 5.6: Resumen de resultados de Prueba 6.

	Promedio [MUSD]	Máximo		Mínimo		Diferencia	
		VPN [MUSD]	Escenario	VPN [MUSD]	Escenario	Total [MUSD]	Promedio [MUSD]
R=6 DET	6.13	6.18	9	6.04	4		
R=6 CPAR	6.13	6.20	16	6.05	4	-0.02	<-0.01
R=7 DET	6.10	6.17	16	6.01	4		
R=7 CPAR	6.12	6.19	16	6.04	8	0.55	0.03
R=10 DET	6.12	6.18	16	6.02	4		
R=10 CPAR	6.14	6.20	7	6.05	8	0.40	0.02

Tabla 5.7: Resumen de resultados de Prueba 7.

	Promedio [MUSD]	Máximo		Mínimo		Diferencia	
		VPN [MUSD]	Escenario	VPN [MUSD]	Escenario	Total [MUSD]	Promedio [MUSD]
R=6 DET	6.11	6.18	16	6.03	8		
R=6 CPAR	6.13	6.22	7	6.06	8	0.58	0.03
R=7 DET	6.12	6.18	16	6.02	8		
R=7 CPAR	6.13	6.21	7	6.06	4	0.37	0.02
R=10 DET	6.10	6.16	16	6.00	8		
R=10 CPAR	6.13	6.22	7	6.07	4	0.80	0.04

Tabla 5.8: Resumen de resultados de Prueba 9.

	Promedio [MUSD]	Máximo		Mínimo		Diferencia	
		VPN [MUSD]	Escenario	VPN [MUSD]	Escenario	Total [MUSD]	Promedio [MUSD]
R=6 DET	6.10	6.17	1	6.02	8		
R=6 CPAR	6.12	6.18	1	6.02	8	0.33	0.02
R=7 DET	6.09	6.17	1	6.00	8		
R=7 CPAR	6.12	6.19	7	6.04	4	0.58	0.03
R=10 DET	6.11	6.18	16	6.01	8		
R=10 CPAR	6.14	6.20	16	6.04	8	0.64	0.03

En la columna de diferencia, el total corresponde a la diferencia de VPN de los radios de conocimiento parcial (CPAR) y determinista (DET), y el promedio al valor anterior dividido por 21 (caso base y los 20 escenarios) para un mismo radio de búsqueda. En general, no se aprecia un comportamiento claro en lo que respecta a un aumento o disminución en la



diferencia de valor entre los casos CPAR y DET al ir aumentando el radio, pero si entre ellos para un mismo radio. Con respecto a lo último, se aprecia que la diferencia favorece al conocimiento parcial en 25 veces (83.3 %) contra 5 (16.7 %) del caso determinista.

En las pruebas 7, 8, 9 y 10 existe un dominio del conocimiento parcial en donde el VPN de los 3 radios de CPAR superan los 3 radios deterministas. La columna de diferencia podría verse como lo que se deja de percibir considerando un caso determinista para un cierto radio de búsqueda.

En la Tabla 5.5 se aprecia que las 3 diferencias favorecen al caso determinista. Esto ocurre también para las pruebas 2 y 6, pero solo para un radio y con un menor impacto en comparación a la prueba 3. Para estudiar el motivo, se realiza un análisis pero solo de la prueba 3 y radio 7 por ser el de mayor promedio de VPN según la Tabla 5.5. Para ello se generan gráficos de leyes de cobre y de valor por caso, además de una figura comparativa de destinos. Esto se puede ver en las Figuras 5.22, 5.23 y 5.24 respectivamente.




Figura 5.22: Gráfico de ley de cobre promedio por caso de la prueba 3 y radio 7.




Figura 5.23: Gráfico de valor económico total por caso de la prueba 3 y radio 7.



Figura 5.24: Diferencias de destino entre casos determinista y conocimiento parcial de la prueba 3 y radio 7.

Los escenarios en los gráficos están ordenados con valores ascendentes asociados al mayor promedio de valor. En la Figura 5.22 la ley de cobre corresponde a la ley que va a planta en donde se observa que las mayores leyes corresponden al caso determinista. Con respecto al valor, Figura 5.23, en la mayoría de los escenarios el caso determinista supera al conocimiento parcial. A modo de conclusión, se puede decir que la diferencia observada entre el caso determinista y conocimiento parcial se da principalmente a la forma de los clusters (bloques que los componen). Esto se aprecia en la Figura 5.24 en la que se pueden ver bloques delimitados por líneas rojas que indican que en el agendamiento de caso base tenían un destino distinto. Esto se muestra para los escenarios 15 y 20, que son dos de los tres escenarios que mostraron las mayores diferencias en lo que respecta al valor entre los casos DET y CPAR.

Como se comenta anteriormente, al ir aumentando el número de representantes también mejora el VPN y esto se debe a la selectividad, lo que se puede ver en las Figuras 5.25, 5.26, 5.27 y 5.28 al ver que van apareciendo más clusters con destino a planta de óxidos en donde antes habían clusters con destino a planta de sulfuro. En las siguientes figuras, el color amarillo representa destino a planta de sulfuros mientras que el morado oscuro a planta de óxidos.




Figura 5.25: Destino de clusters de prueba 1, escenario 11 y R=10.




Figura 5.26: Destino de clusters de prueba 3, escenario 7 y R=7.




Figura 5.27: Destino de clusters de prueba 5, escenario 11 y R=6.




Figura 5.28: Destino de clusters de prueba 10, escenario 7 y R=10.

### 5.3.2. Efecto número mínimo de bloques

Ahora se comenta la diferencia entre las pruebas 5, 8 y 9 (en donde se podían hacer clusters con un mínimo de 10 bloques) y las pruebas 6, 7 y 10 (en las que el mínimo de bloques es de 8), tal como se observa en la Tabla 5.3. Se aprecia que en general las pruebas 6 y 7 presentan mayores promedios de VPN en comparación a las 5 y 8 respectivamente, mientras que la prueba 9 lo hace sobre la 10. En otras palabras, 2 veces fue superior tener la posibilidad de generar clusters con un mínimo de 8 bloques en comparación a 1 vez de poder hacerlos con un mínimo de 10, tanto para el caso DET como CPAR. Esto ocurre debido a que tener clusters más pequeños permite ser más selectivo. Algunos ejemplos se pueden ver en las Figuras 5.29, 5.30 y 5.31.




Figura 5.29: Gráfico de VPN de CPAR de las pruebas 5 y 6 con radio 6.




Figura 5.30: Gráfico de VPN determinista de las pruebas 7 y 8 con radio 10.




Figura 5.31: Gráfico de VPN determinista de las pruebas 9 y 10 con radio 7.

### 5.3.3. Saturación de destinos y secuencia de extracción

Se estudia la ocupación de los distintos destinos disponibles para el CPAR y se observa que el modelo le da prioridad al destino de planta de sulfuro dado que su recuperación es mayor y ese tipo de minerales poseen mayores leyes (como indica la Tabla 5.1). Es por eso que en la Figura 5.32 se observa que la utilización de la planta de sulfuros, para el radio 6, en los primeros 3 periodos es de mínimo un 75% en promedio mientras que la planta de óxidos (Figura 5.33) para el radio 10, es bastante diferente, llegando a operar en casi 2 periodos completos bajo el 50% de su capacidad máxima. Los gráficos de los radios 7 y 10, y 6 y 7 para la planta de sulfuro y óxidos respectivamente, se pueden ver en la sección Anexos A.

Finalmente, a diferencia de la secuencia de extracción del ANB (Figura 5.11), ahora en algunos casos se aprecia un avance más ordenado en la secuencia de extracción mientras que en otros la secuencia no es tan ordenada y sencillas de llevar a cabo. Un ejemplo se puede ver en la Figura 5.34.




Figura 5.32: Ocupación de planta de sulfuros para radio 6.




Figura 5.33: Ocupación de planta de óxidos para radio 10.




Figura 5.34: Orden de extracción de los clusters.

A modo de resumen, el conocimiento parcial genera en un 83% de los casos un mayor promedio de VPN en comparación al caso determinista. A diferencia del agendamiento a nivel de bloque (ANB), los promedios de VPN de los casos DET y CPAR están muy por debajo (esto se analiza más en detalle en la sección 5.4), siendo como mínimo de 530 mil USD. Pero, por otro lado, en la Figura 5.34 se ve un orden de extracción mucho más ordenado y factible de llevar a cabo en comparación al del ANB (Figura 5.11).

## 5.4. Conocimiento Perfecto

Para el estudio de conocimiento perfecto (CP), se utilizan 56 representantes (28 por banco), todos separados cada 3 bloques en la dirección X e Y partiendo del bloque de la segunda fila y columna de la esquina inferior izquierda de cada banco. En este caso, se generan 6 pruebas (4 con 3 radios y 2 con 2 radios). Al igual que en los casos anteriores, los clusters se componen como máximo por 50 bloques, pero el mínimo varía. Por otro lado, en este caso se pone un máximo número de cluster que puede usar cada prueba para estudiar que representantes escoge el modelo de optimización y su efecto. En la Tabla 5.9 se aprecia un resumen de la cantidad de representantes usados y el número máximo y mínimo de bloques por cluster permitidos en cada prueba. Por otro lado, en la Figura 5.35 se puede ver la distribución de los representantes (en amarillo) para esta parte del estudio.




Figura 5.35: Ubicación bloques representantes de conocimiento perfecto.

Tabla 5.9: Pruebas realizadas para el caso de conocimiento perfecto.

Pruebas	Máximo N° clusters	Radio de búsqueda			Bloques por cluster	
					Mínimo	Máximo
P11	56	6	7	10	10	50
P12	56	6	7	10	8	50
P13	30	6	7	10	10	50
P14	30	6	7	10	8	50
P15	20	-	8	10	10	50
P16	20	-	8	10	8	50

### 5.4.1. Valor Económico

En las Tablas 5.10, 5.11 y 5.12 se pueden ver los resultados de las pruebas 12, 13 y 16 respectivamente. Los resultados de las otras pruebas se pueden encontrar en la sección de Anexos B.

Tabla 5.10: Resumen de resultados de Prueba 12.

		Máximo		Mínimo	
	Promedio [MUSD]	VPN [MUSD]	Escenario	VPN [MUSD]	Escenario
<b>R=6</b>	6.19	6.26	16	6.09	8
<b>R=7</b>	6.20	6.25	7	6.12	8
<b>R=10</b>	6.20	6.25	7	6.13	8

Tabla 5.11: Resumen de resultados de Prueba 13.

		Máximo		Mínimo	
	Promedio [MUSD]	VPN [MUSD]	Escenario	VPN [MUSD]	Escenario
<b>R=6</b>	6.15	6.20	7	6.08	8
<b>R=7</b>	6.15	6.21	1	6.07	8
<b>R=10</b>	6.16	6.20	16	6.08	8

Tabla 5.12: Resumen de resultados de Prueba 16.

		Máximo		Mínimo	
	Promedio [MUSD]	VPN [MUSD]	Escenario	VPN [MUSD]	Escenario
<b>R=8</b>	5.89	5.94	16	5.82	17
<b>R=10</b>	5.96	6.02	16	5.89	4

En las Figuras 5.36, 5.37 y 5.38 se pueden ver gráficos de VPN en función del radio para todos los escenarios. En ellas se aprecia que casi todos los valores máximos por escenario se encuentran en la prueba 12. El motivo de esto se comenta más adelante. En las figuras, las curvas de color naranja corresponden a la prueba 12, gris a la prueba 13, amarillo a la prueba 14 y verde a la prueba 16. Cabe señalar, que los escenarios están ordenados de menor a mayor VPN para la prueba que presenta el mayor promedio de VPN. Los gráficos con todas las pruebas se pueden ver en la sección de Anexos B.






Figura 5.36: Gráfico de VPN de conocimiento perfecto de radio 6.




Figura 5.37: Gráfico de VPN de conocimiento perfecto de radio 7.




Figura 5.38: Gráfico de VPN de conocimiento perfecto de radio 10.

### 5.4.2. Efecto número mínimo de bloques

En las Figuras 5.39, 5.40 y 5.41 se aprecian gráficos de VPN de las pruebas 11 y 12, 13 y 14, y 15 y 16, respectivamente, en donde se ve que las pruebas en los que se toma como condición que los clusters se pueden generar como mínimo con 8 bloques (12, 14 y 16) y para un radio 10 son los que tienen el mayor promedio de VPN (esto también se puede ver de las Tablas B.1, 5.10, 5.11, B.2, B.3 y 5.12), pero en general se ve un dominio de los valores adquiridos con clusters con un mínimo de 8 bloques para cualquier radio.




Figura 5.39: Gráfico de VPN de conocimiento perfecto de pruebas 11 y 12 para radio 10




Figura 5.40: Gráfico de VPN de conocimiento perfecto de pruebas 13 y 14 para radio 6.




Figura 5.41: Gráfico de VPN de conocimiento perfecto de pruebas 15 y 16 para radio 10.

Para explicar la diferencia en VPN entre las pruebas que pueden generar clusters con mínimo 8 y 10 bloques, primero se ve cuantos clusters se generan en cada prueba. En la Tabla 5.13 se ve en promedio los representantes usados (en otras palabras, los clusters generados) por prueba.

Tabla 5.13: Promedio de representantes usados por prueba y radio.

	Promedio de representantes usados		
	R=6	R=7	R=10
<b>P11</b>	39.00	38.52	39.24
<b>P12</b>	43.19	43.90	43.19
<b>P13</b>	30.00	30.00	29.95
<b>P14</b>	30.00	30.00	30.00
	<b>R=8</b>	<b>R=10</b>	-
<b>P15</b>	20.00	20.00	-
<b>P16</b>	20.00	20.00	-

Como se observa en la Tabla 5.13 en las pruebas 13, 14, 15 y 16 se generaron todos los clusters permitidos, pero no así en las pruebas 11 y 12. Cabe señalar, que muy pocas veces se generaron más clusters en el banco 1 en comparación al banco 0, pero en las pruebas 11 y 12 se generaron por radio en promedio 2 clusters más en el banco 0 mientras que en las pruebas 13 y 14, en promedio 7. Con esto se puede observar, que el modelo genera mayor cantidad de clusters en el banco 0 por su mayor variabilidad en lo que respecta al destino a nivel de bloque.

En relación con lo observado de la prueba 12, ese efecto se da por la cantidad de clusters que puede generar. En la prueba 15 y 16, al poner 20 como la máxima cantidad de clusters

disponibles, eso limita a tener que mandar bloques a un cierto destino que no es conveniente, pero al tener la posibilidad de generar 56 clusters es posible hacer clusters más pequeños con el objetivo de aumentar el valor. Debido a esto es que se da esta gran diferencia entre la prueba 12 y las pruebas 15 y 16, porque se puede ser más selectivo. Un ejemplo de los clusters generados se puede apreciar en la Figura 5.42, en donde los clusters se encuentran delimitados con líneas rojas. Los escenarios corresponden a aquellos que generaron los valores económicos más elevados, que para las pruebas 12 y 16 corresponde a los escenarios 7 y 16 respectivamente. Para el caso de la prueba 12, solo se generaron 3 de 46 clusters con 20 o más bloques (siendo el máximo de 38). Mientras que, en la prueba 16, 11 de los 20 clusters generados estaban compuestos por 20 o más bloques. Por otro lado, cabe mencionar, que el color mostrado de los bloques señala el mejor destino del bloque, lo que indica al tener más clusters se tiene menos mezcla.



Figura 5.42: Diferencia de clusters generados para las pruebas 12 (arriba) y 16 (abajo).

Otra explicación a las diferencias observadas puede estar en la ubicación de los representantes ocupados. Se calcula la frecuencia de selección de los candidatos por coordenada Y, y por lo general los escogidos están en la zona central del modelo de bloques. Esto se puede observar en la Tabla 5.14. A excepción de la prueba 12, a medida que se aumenta en las pruebas, disminuye la cantidad de representantes usados por Y, llegando a 0 en las pruebas 15 y 16 en la coordenada Y=50 de cada banco. Por otro lado, en la coordenada Y=20 de ambos bancos son los que mayor ocupación tienen en todas las pruebas. En las últimas 4 pruebas,

para el banco 1, el dominio de representantes escogidos estaba en las coordenadas Y=20 e Y=35, porque es en esa zona aproximadamente donde está el “límite” entre sulfuros y óxidos. Lo que se puede concluir de esto, es que el modelo por sí solo no aporta la mejor solución al problema, por lo que es necesaria la ayuda de un ingeniero para poder encontrar la mejor ubicación de los representantes. En la Figura 5.43 se aprecia una comparación de la curva de VPN obtenida para la prueba 15 (20 representantes) contra las curvas CPAR obtenidas para las pruebas 1, 2 y 8 en donde las 2 primeras usaban 12 representantes mientras que la tercera 20. Se puede observar que se obtuvo levemente un mejor VPN con 12 representantes, en la prueba 1, en comparación a 20 representantes en la prueba 15, mientras que en la prueba 8 (con 20 representantes) se obtiene en promedio un VPN aproximadamente 175 mil USD superior a la prueba 15.

Tabla 5.14: Porcentaje de uso de representantes por banco y coordenada Y.

Y	Banco	P11 [%]	P12 [%]	P13 [%]	P14 [%]	P15 [%]	P16 [%]
5	0	44.67	60.32	31.75	30.39	14.63	14.97
20		100.00	100.00	100.00	99.77	80.95	81.29
35		61.00	79.59	50.57	51.47	48.98	48.64
50		85.71	96.15	85.71	85.71	0.00	0.00
5	1	36.28	51.02	16.78	15.42	14.29	14.29
20		100.00	99.32	85.71	85.94	71.43	71.43
35		43.08	40.59	57.82	56.92	55.44	55.10
50		85.26	93.42	0.00	2.95	0.00	0.00




Figura 5.43: Gráfico comparativo de VPN de distintas pruebas con radio 10.

### 5.4.3. Saturación de destinos

Similarmente a lo ocurrido con la ocupación de destinos del caso de conocimiento parcial, en este caso el modelo también manda más material a la planta de sulfuros llegando a ocupar en los primeros 3 periodos mínimo un 90 % de su capacidad (mayor ocupación que en los casos anteriores). Por otro lado, en el caso de la utilización de la planta de óxidos, el escenario es al revés, siendo su utilización menor a los casos anteriores. Algunos ejemplos se pueden ver en la Figuras 5.44 y 5.45 para la planta de sulfuros y óxidos respectivamente. En la sección Anexos B se pueden ver los gráficos de los otros radios y una tabla con el promedio de tonelaje de material enviada a cada planta.




Figura 5.44: Ocupación de planta de sulfuros de CP para radio 6.




Figura 5.45: Ocupación de planta de óxidos de CP para radio 10.

### 5.4.4. Comparación ANB, DET, CPAR Y CP con recuperación fija

A modo de comparación, en la Figura 5.46 se muestra un gráfico que junta la prueba que mejor promedio de VPN tuvo para cada tipo de caso (determinista, conocimiento parcial y

conocimiento perfecto) con el agendamiento a nivel de bloque para ver las diferencias entre cada una de ellas. Mientras que en la Figura 5.47, se observa lo mismo pero sin el ANB. En los gráficos, la curva de color amarillo corresponder a la prueba 12 y radio 10, la color gris corresponde a la prueba 9 y radio 10, y la de color naranja a la prueba 6 y radio 6.




Figura 5.46: Gráfico de los mejores VPNs de cada caso de estudio junto con ANB.




Figura 5.47: Gráfico de los mejores VPNs de cada caso sin ANB.

Como se observa en la Figura 5.46 existe una diferencia en promedio de aproximadamente 520 mil USD entre los distintos estudios generados y el agendamiento a nivel de bloque, pero por otro lado, se sabe que el ANB no se puede llevar a cabo dado que no se pueden extraer bloques de una forma tan selectiva como lo muestra la Figura 5.11, donde inclusive hay bloques rodeados por otros bloques se extraen en periodos posteriores. Por otro lado, en la Figura 5.47 se aprecia una superioridad de la prueba de conocimiento perfecto (máximo 56 clusters posibles) en comparación a las pruebas que mejor promedio de VPN aportaron para los casos DET y CPAR, con una diferencia de aproximadamente 65 mil USD.

## 5.5. Recuperación Variable

En las sub secciones anteriores se hace uso de una recuperación constante lo que en las plantas de recuperación no ocurre. Es por eso, que en esta sub sección se utilizan curvas de recuperación metalúrgica provenientes de una operación minera del norte de Chile, en función a la ley de alimentación, para ambas plantas de procesamiento y que se pueden ver en la Figura 5.48.




Figura 5.48: Curvas de recuperación usadas.

Las ecuaciones que describen las curvas de recuperación de sulfuros y óxidos se pueden ver en las Ecuaciones 5.1 y 5.2, respectivamente, y en donde el  $L$  representa la ley de cobre de la mineralización adecuada. Por otro lado, el  $R^2$  de la ecuación de recuperación de óxidos es de 0.999 y de sulfuros es de 0.998.

$$R_{SULF} = (0,1513 \cdot (L^5)) - (1,1918 \cdot (L^4)) + (3,5687 \cdot (L^3)) - (5,0331 \cdot (L^2)) + (3,3509 \cdot L) + 0,0053 \quad (5.1)$$

$$R_{OX} = (0,2116 \cdot (L^3)) - (0,9768 \cdot (L^2)) + (1,512 \cdot L) + 0,0004 \quad (5.2)$$

Estas ecuaciones de recuperación se aplican para el ANB, CPAR y CP. En el caso de las 2 últimas, se aplica para cada prueba pero solo para el radio que presenta el mayor promedio de VPN con recuperación constante. En la Tabla 5.15 se puede ver un resumen de las pruebas realizadas con recuperación variable.



Tabla 5.15: Pruebas realizadas con recuperación variable.

Pruebas	Candidatos	Radio de Búsqueda	Máximo N° Clusters	Bloques por cluster	
				Mínimo	Máximo
P1RV	12	10	-	10	50
P2RV	12	10	-	10	50
P3RV	12	10	-	10	50
P4RV	14	10	-	10	50
P5RV	18	7	-	10	50
P6RV	18	10	-	8	50
P7RV	20	6	-	8	50
P8RV	20	10	-	10	50
P9RV	21	10	-	10	50
P10RV	21	10	-	8	50
P11RV	56	10	56	10	50
P12RV	56	10	56	8	50
P13RV	56	10	30	10	50
P14RV	56	10	30	8	50
P15RV	56	10	20	10	50
P16RV	56	10	20	8	50

### 5.5.1. Valor Económico

El agendamiento a nivel de bloque entregó un promedio de 6.36 MUSD, 313 mil USD menos que con recuperación constante. En las Tablas 5.16 y 5.17 se puede ver el VPN promedio, máximo y mínimo y a que escenario corresponde cada uno. También aparece una columna de *diferencia* que muestra la diferencia entre el promedio con recuperación variable y con recuperación contante para cada prueba. Se observa, que en todas las pruebas se tiene un VPN por lo menos 250 mil USD menor con respecto a recuperación constante. Esto esta fuertemente relacionado a las curvas de recuperación escogidas y al mismo tiempo, afecta el destino que se le da a los bloques.

Como se muestra en la Tabla 5.1, se aprecia que el 3er cuartil de los óxidos corresponde a 0.75 % mientras que el de sulfuros a 1.07 %. En los casos anteriores se usaba una recuperación constante del 75 % para óxidos y 85 % para sulfuros, lo que en las curvas de recuperación (Figura 5.48) corresponde a 1 % de ley de óxidos y 1 % de ley de sulfuros respectivamente. Esto quiere decir, que más del 75 % de los bloques de óxidos tienen recuperación menor al 75 %. Mientras que en el caso de sulfuros, aproximadamente el 75 % de los bloques tienen recuperación menor al 85 %. Esto afecta al VPN del proyecto.

Otra cosa a observar en las Tablas 5.16 y 5.17, es que en general, las pruebas en las que se podían generar clusters con un mínimo de 8 bloques generan un promedio de VPN mayor

a su símil pero con un mínimo de 10 bloques.

Tabla 5.16: Resumen de resultados de las pruebas CPAR con recuperación variable.

	Promedio [MUSD]	Máximo		Mínimo		Diferencia [MUSD]
		VPN [MUSD]	Escenario	VPN [MUSD]	Escenario	
<b>P1RV</b>	5.70	5.78	16	5.60	4	-0.28
<b>P2RV</b>	5.67	5.76	16	5.58	4	-0.27
<b>P3RV</b>	5.67	5.76	16	5.56	4	-0.27
<b>P4RV</b>	5.77	5.85	16	5.71	8	-0.26
<b>P5RV</b>	5.86	5.93	1	5.77	8	-0.27
<b>P6RV</b>	5.87	5.97	16	5.81	8	-0.27
<b>P7RV</b>	5.87	5.93	16	5.77	8	-0.26
<b>P8RV</b>	5.86	5.93	16	5.78	4	-0.27
<b>P9RV</b>	5.87	5.95	16	5.79	8	-0.27
<b>P10RV</b>	5.88	5.98	16	5.78	8	-0.26

Tabla 5.17: Resumen de resultados de las pruebas CP con recuperación variable.

	Promedio [MUSD]	Máximo		Mínimo		Diferencia [MUSD]
		VPN [MUSD]	Escenario	VPN [MUSD]	Escenario	
<b>P11RV</b>	5.92	5.99	7	5.85	8	-0.25
<b>P12RV</b>	5.95	6.03	16	5.86	8	-0.25
<b>P13RV</b>	5.90	5.97	16	5.82	8	-0.26
<b>P14RV</b>	5.92	5.98	16	5.83	8	-0.26
<b>P15RV</b>	5.69	5.78	16	5.61	4	-0.26
<b>P16RV</b>	5.69	5.78	16	5.61	4	-0.26

En las Figuras 5.49 y 5.50 se pueden observar gráficos de VPN para algunas pruebas usando recuperación variable. En la Figura 5.49 se observa lo mismo que se observaba en los otros casos, que a medida que aumenta el número de representantes aumenta el VPN. En ese gráfico, el color naranja corresponde a la prueba 2, el amarillo a la prueba 4 y el marrón a la prueba 10. Mientras que en la Figura 5.50, ahora se puede ver el VPN en función del

número máximo de clusters que se podían generar en la que se aprecia que tener más clusters genera un mejor VPN. En el gráfico, la curva de color naranja corresponde a la prueba 12, la de amarillo a la prueba 14 y la verde a la prueba 16. Los gráficos con todas las curvas se pueden observar en la sección de Anexos C.




Figura 5.49: Gráfico de valor económico de algunas pruebas de conocimiento parcial con recuperación variable.




Figura 5.50: Gráfico de valor económico de algunas pruebas de conocimiento perfecto con recuperación variable.

### 5.5.2. Saturación de destinos

En lo que respecta a la ocupación de destino, tanto para el caso de conocimiento perfecto como parcial, se tiene una mejor utilización de la planta de sulfuros mientras que para la planta de óxidos en algunas pruebas mejora levemente pero en otras no. En las Figuras 5.51 y 5.52 se puede ver la utilización de la planta de óxidos y sulfuros de conocimiento perfecto respectivamente. Las figuras de utilización de destinos para conocimiento parcial se encuentran en la sección Anexos C.




Figura 5.51: Ocupación de planta de óxidos de CP con recuperación variable.




Figura 5.52: Ocupación de planta de sulfuros de CP con recuperación variable.

# Capítulo 6

## Análisis

Se utiliza una metodología cuyo principal objetivo es generar una planificación minera de corto plazo. Esto lo consigue a través de bloques *candidatos a ser bloques representantes*, que en caso de ser escogidos, generan clusters a través de distintas restricciones. Es efectivo y tiene un tiempo de ejecución menor a los 50 minutos para los casos realizados en los estudios deterministas y conocimiento parcial, pero puede llegar a 32 horas para estudios como los realizados para el conocimiento perfecto (como la prueba 16 y radio 10).

Como se comenta en la sección 3, los arcos de precedencia sirven para darle forma y conectividad a los clusters, pero estos dependen del orden de extracción que se les dé a los bloques representantes. Durante la ejecución del modelo se utilizan arcos de precedencia tipo *Tree* que genera que se defina, previamente a la formación de los clusters, el orden de extracción de los bloques representantes. Esto último puede provocar que a veces se generen clusters cuya geometría haga que no sean factibles de llevar a cabo en la realidad y que generen problemas operacionales. Ejemplo de esto pueden ser clusters rodeados por otros clusters cuyo destino es diferente, rodeados por cluster cuyo periodo de extracción es diferente o cortado por clusters que tienen otro periodo de extracción. Esto hace que se requiera de la experiencia de un experto para suavizarlos o arreglarlos y poder llevarlos a cabo, pero, por otro lado, este trabajo extra requiere de tiempo. En la Figura 6.1, arriba, se observa un cluster delimitado por líneas negras. El destino de ese cluster es la planta de óxidos y esta rodeado por clusters (que no se encuentran delimitados) cuyo destino es la planta de sulfuros y salen en el mismo periodo. Por otro lado, su geometría no facilita la extracción. En la figura de al medio de la Figura 6.1 se puede ver que en el banco 0 (izquierda) se tienen clusters cuyo periodo de extracción es el 2 (color azul) que cortan el avance de extracción de bloques que se extraen en el periodo 1 (color morado). Como último ejemplo, abajo en la Figura 6.1 se aprecia que en el banco 0 el primer bloque que se debe de extraer por banco es el de la esquina inferior izquierda y en ese agendamiento, el primero sale en el periodo 2 pero en ese mismo banco hay bloques que están agendados en el periodo 1.

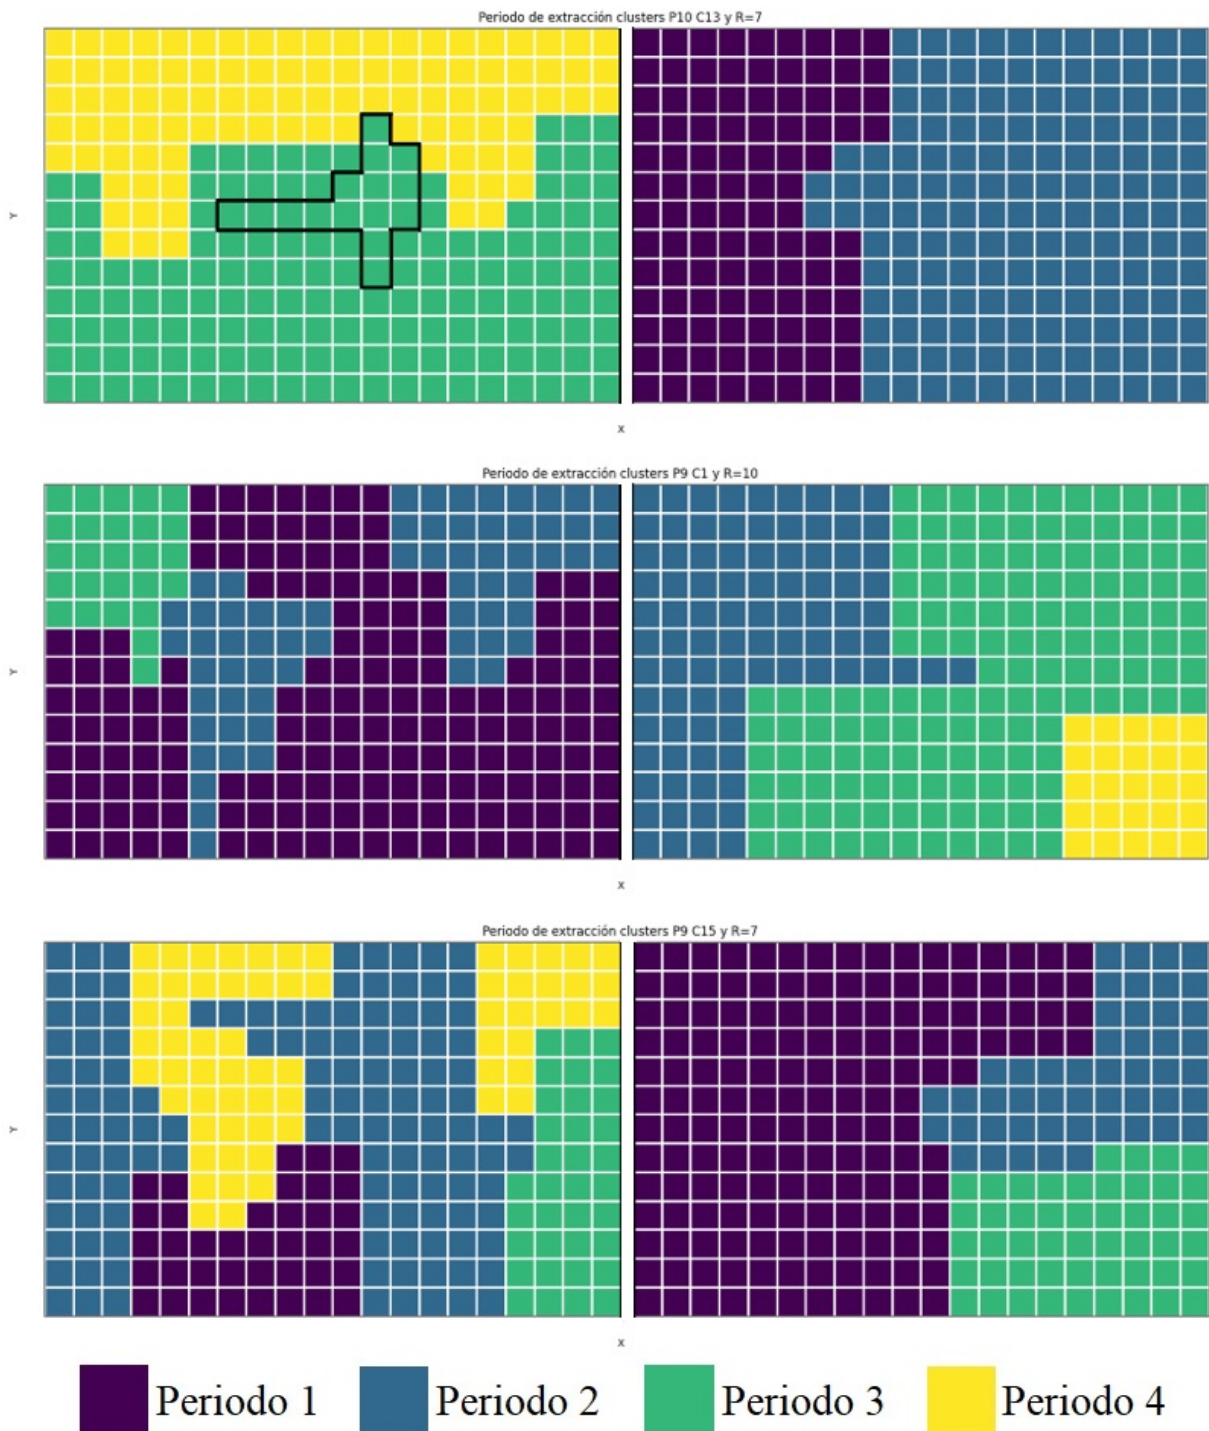


Figura 6.1: Ejemplos de algunos problemas de agendamiento.

En los distintos casos de estudio expuestos en la sección 5, se observa que a medida que se aumenta en el número de bloques representantes, aumenta el VPN del proyecto. Esto se relaciona a que se pueden generar más clusters, más pequeños y por ende, ser más selectivos. Por otro lado, todos están lejos, en términos de VPN, a lo obtenido en el agendamiento a nivel de bloque (ANB) pero a diferencia de los estudios con bloques representantes, el ANB

no es factible de llevar a cabo operacionalmente.

En los casos de estudio DET y CPAR se observó que en general los VPN relacionados al conocimiento parcial obtuvieron mejores resultados a excepción de la prueba 3. Esto último se comprobó en las Figuras 5.22, 5.23 y 5.24 que se debe a los bloques que componen los clusters, que para esa prueba, favorecen al caso de estudio determinista. Por otro lado, para estos mismos casos, se estudió la diferencia de poder generar clusters con un mínimo de 8 y 10 bloques mostrando que en general se obtienen mejores resultados al generar clusters más pequeños.

Al entregar 56 candidatos, como se hace en las pruebas de conocimiento perfecto, se da la oportunidad de que el modelo escoja los representantes a usar. Una diferencia entre los estudios de conocimiento parcial y determinista, y conocimiento perfecto es que este último en las pruebas 11, 12, 13 y 14 presenta mayores promedios que en todas las pruebas de CPAR y DET por tener la posibilidad de generar clusters más pequeños y más selectivos.

La diferencia observada entre las pruebas 15 y 16 con el resto de las pruebas de conocimiento perfecto se relaciona con el número de clusters que se pueden generar, que se demostró con la Figura 5.42. Es interesante ver que en las pruebas 15 y 16, se da la opción de generar 20 clusters y el modelo casi todos los representantes los escoge en la zona central del caso de estudio, donde existe mayor variabilidad, en vez de buscar otra configuración como por ejemplo similar a la de la prueba 9 (21 candidatos). Esta última prueba, fue la que entregó el promedio de VPN más elevado para los casos DET y CPAR.

Se genera un estudio con recuperación variable dado que en las plantas de procesamiento de las empresas mineras no se tiene recuperación constante de los distintos elementos de interés. Al aplicar las curvas de la Figura 5.48 se tienen en promedio 313 mil USD menos en el ANB, 267 mil USD menos en CPAR y 257 mil USD menos en CP. Esto se da principalmente por las leyes que posee el depósito, siendo la gran mayoría menores a la ley necesaria para tener el 75 % y 85 % de recuperación de óxidos y sulfuros respectivamente que se usó en una parte del estudio. Esto genera que aumente el material que es enviado a planta de sulfuros y por consiguiente, que se modifique la secuencia de extracción.

Otro factor que puede afectar a la diferencia en valor económico, que se menciona en el sección 3, es que los clusters pueden estar generados por bloques cuyo mejor destino no sea precisamente el destino del cluster. Si se comparan las Figuras 5.10 (ANB), 5.32 y 5.33 (conocimiento parcial), y 5.44 y 5.45 (conocimiento perfecto) se aprecia que en el ANB se tienen aproximadamente 152 mil toneladas de material que va a planta de óxidos mientras que en las pruebas de los casos de CPAR y CP se tienen como 15 mil y 18 mil toneladas menos de material (que se va a planta de sulfuros) con un menor valor. Por otro lado, lo mismo ocurre con bloques que en el ANB iban a planta de sulfuros, pero su impacto es menor.

Otros factores que pueden afectar la diferencia de VPN entre el ANB y los otros casos de estudio son el periodo de agendamiento y el tamaño de los clusters. En el primero hay que considerar la devaluación del dinero en el tiempo. Al momento de generar clusters para su extracción depende mucho desde donde se parte dicha extracción (que para efectos de este estudio se hace desde la esquina inferior izquierda de cada banco) y de la ubicación de los bloques de altas leyes para cada mineralización. En lo que respecta al tamaño de los clusters,

afecta el VPN porque afecta a la cantidad de bloques que se pueden enviar por periodo a la planta de procesamiento. Pero el tamaño de los clusters, como se comenta anteriormente, esta ligado al número de bloques representantes disponibles. Como se aprecia en las Figuras 5.32 y 5.44, en donde en el segundo caso al generar clusters más pequeños, debido a la mayor disponibilidad de bloques representantes, permite tener una mejor utilización de esta.

En lo que respecta a la utilización de destinos pero usando recuperación variable (cuyos gráficos se pueden observar en las Figuras 5.51, 5.52 y en la sección de Anexos C) se aprecia que en general la utilización de la planta de sulfuros mejoro en todos los periodos sobretodo para el periodo 4. Por otro lado, la planta de óxidos muestra una peor utilización. En promedio, se mandan 13 mil toneladas menos de material en el caso CPAR mientras que unas 10 mil toneladas menos de material para el caso CP (comparando esos mismos casos pero con recuperación constante). Esto ocurre porque la curva de recuperación empleada en el estudio no es tan favorable para los óxidos, pero tampoco lo es para los sulfuros, porque el VPN tendría una variación menor a la que tiene.

De forma general, en muy pocos casos se logra tener un 100% de ocupación de planta de óxidos en alguno de los periodos e incluso hay ocasiones en los que el material que va a planta de óxidos queda para un periodo  $t+1$  cuando la planta en periodo  $t$  está vacía o funcionando bajo el 60% de su capacidad. Esto puede tener diversos motivos. Uno puede ser por la cantidad de material que en promedio va a planta de óxidos; otro porque no se genera una restricción que haga que las plantas de procesamiento trabajen a una cierta capacidad; y otro por la forma en que el arco de precedencias tipo *Tree* genera el orden de extracción de los representantes. Estos motivos pueden afectar el VPN generado en el proceso de agendamiento y al mismo tiempo a los bloques que componen los clusters.

Para finalizar, cabe recordar que el modelo no aplica ninguna penalización por no cumplir con una cierta cantidad de material enviada a cada una de las plantas, extracción en la mina, o calidad del producto final. De tener alguna de estas restricciones, la distribución de los clusters y los bloques que los componen seria diferente para todos los casos de estudio para ambos tipos de recuperación.



# Capítulo 7

## Conclusiones y Trabajo Futuro

En esta sección se presentan las principales conclusiones de esta tesis y los trabajos futuros a realizar.

- Se emplea una metodología cuyo principal objetivo es generar un agendamiento de corto plazo utilizando bloques candidatos a ser bloques representantes con lo que generan clusters. El modelo de optimización presentó distintos tiempos de ejecución a lo largo de las distintas pruebas realizadas.
- El modelo de optimización utiliza arcos de precedencia para darle forma y conectividad a los clusters, tal como se indica en la sección 3. En esta tesis, se utilizan arcos tipo *Tree* pero generaba en algunos casos geometrías irregulares y operacionalmente difíciles de llevar a cabo.
- Con respecto a los distintos planes obtenidos, en muy pocos casos se logra tener 100 % de utilización de planta, por lo general ocurre en 1 o 2 periodos y principalmente para la planta de sulfuros. Existen periodos  $t$  en los que una planta no tiene material pero si en el siguiente,  $t+1$ , y esto puede estar relacionado a diversos motivos antes mencionados.
- Otro motivo que afecta la utilización de las plantas de procesamiento es el tamaño de los clusters y la ubicación de los bloques representantes. Entre menos candidatos a bloques representantes se le entreguen al modelo, mayores clusters va a generar. Por ejemplo, en las pruebas 1, 2 y 3 en los que se le entregaron 12 candidatos al modelo (y generó 12 clusters) en promedio se deberían de generar clusters de 43-44 bloques mientras que en las pruebas 11 y 12, donde se entregan 56 candidatos, se deberían generar en promedio clusters de 9-10 bloques.
- En relación a las pruebas realizadas, se comprueba que a medida que se aumentan los representantes mejora el VPN del proyecto. Por otro lado, su ubicación también la afecta principalmente en el orden de extracción. El aumento de los bloques representantes permite tener clusters más pequeños y ser más selectivos, por eso es que se ve un aumento en el VPN a medida que se aumenta el número de representantes. A excepción de la prueba 3, en todas las demás se ve una superioridad del conocimiento parcial por sobre el determinista.

- En el estudio de conocimiento perfecto es donde se logra tener los mejores VPNs utilizando clusters. En 4 pruebas (11, 12, 13 y 14) de este caso se generaron mejores resultados en comparación a todas las pruebas CPAR y DET. Por otro lado, las pruebas 15 y 16, en las que se podía generar como máximo 20 clusters, generaron uno los promedio de VPN más bajos con recuperación constante de todo el estudio.
- Se repiten algunas pruebas con un solo radio pero usando curvas de recuperación metalúrgicas para ambas plantas de procesamiento. Los resultados no son favorables para ningún tipo de mineralización, pero su efecto es más notorio con los óxidos. Por otro lado, lo que si mejoró en este caso, es la utilización de la planta de sulfuros.
- Se intenta hacer un estudio en el que se le entrega al modelo de optimización la posibilidad de escoger 56 representante entre 520 candidatos (es decir, cualquier bloque podía ser bloque representante) pero el modelo se caía poco después de comenzar. Luego, se intento con la mitad de candidatos, es decir 260 (130 por banco, distribuidos de forma intercalada) y al igual que el caso anterior, no se obtuvieron resultados pero en este caso el modelo corrió durante 10 días sin caerse. Como un futuro estudio, se propone modificar el enfoque del código a una heurística, específicamente a *simulated annealing*, que si bien no entrega una solución óptima al problema pero puede soportar la cantidad de variables que tiene debido a su gran tamaño.
- Como se menciona en la sección 2.4.1, la mineralogía también juega un rol muy importante en la etapa de procesamiento de minerales. Distintos minerales, como los filosilicatos, pueden adherirse a la superficie de minerales económicamente importantes (como calcopirita) e impedir que floten o pueden llegar al concentrado elementos contaminantes (como el arsénico) que afectan el valor del producto final. Es por ello que sería interesante estudiar el efecto de tener información geológica (por ejemplo, descripción de muestras de mano y de cortes transparentes). Esto con el objetivo de poder ligarlas a algún efecto de proceso metalúrgico (recuperación en celda de flotación, tiempo de residencia en un molino de bolas o SAG, etc.) para así tener variables geometalúrgicas y estas poder aplicarlas en el proceso de agendamiento para estudiar el impacto que estas tienen. En este estudio se mostró el impacto de utilizar curvas de recuperación metalúrgicas, obteniendo menores valores económicos en comparación a la recuperación constante pero sin hacer uso de información geológica.
- Se demuestra en este estudio la importancia de aplicar distintos escenarios geológicos dado que se tienen distintas soluciones en lo que respecta a VPN, ocupación de destinos, secuencias de extracción, entre otros. En este estudio, el caso base (caso 0) se encontraba entre las más bajas en VPN. Por otro lado, en la presente tesis se generan 20 escenarios para ver la incertidumbre, pero se propone como estudio analizar esto para ver si con 20 escenarios es suficiente.
- Por otro lado, los escenarios geológicos se generan insertando un ruido que depende de la varianza de los datos, por ende, no son equiprobables. Es por eso, que también se propone generar un estudio similar pero esta vez mediante técnicas de simulación geoestadística para generar una cierta cantidad de escenarios equiprobables y ver un efecto más real de la incertidumbre geológica en el proceso de planificación minera.

# Bibliografía

- Albor Consuegra, F. R. y R. Dimitrakopoulos (2009). “Stochastic mine design optimisation based on simulated annealing: pit limits, production schedules, multiple orebody scenarios and sensitivity analysis”. En: *Mining Technology* 118.2, págs. 79-90. DOI: 10.1179/037178409X12541250836860
- Alves Campos, P. H., J. F. Coimbra Leite Costa, V. C. Koppe y M. A. Arcari Bassani (2021). “Geometallurgy-oriented mine scheduling considering volume support and non-additivity”. En: *Mining Technology* 131.1, págs. 1-11
- Basnayaka, L., N. Subasinghe y B. Albijanic (2017). “Influence of clays on the slurry rheology and flotation of a pyritic gold ore”. En: *Applied Clay Science* 136, págs. 230-238
- Boogaart, K. G. Van den, C. WEIßFLOG y J. GUTZMER (2011). “The value of adaptive mineral processing based on spatially varying ore fabric parameters”. En: *Proceedings of IAMG*. Vol. 2011. DOI: 10.5242/iang.2011.0265
- Bulatovic, S., D. M. Wyslouzil y C. Kant (1999). “Effect of clay slimes on copper, molybdenum flotation from porphyry ores”. En: *Proceedings of Copper*
- Casali, A. (2019). *Fundamentos de Procesos Mineralúrgicos*. Apuntes de curso. Departamento de Ingeniería de Minas, Facultad de Ciencias Físicas y Matemáticas, Universidad de Chile.
- Cochilco (2021). *Anuario de Estadísticas del Cobre y Otros Minerales 2001-2020*.
- Coward, S. y P. A. Dowd (2015). “Geometallurgical models for the quantification of uncertainty in mining project value chains”. En: *International Symposium on the Application of Computers and Operations Research in the Mineral Industry (APCOM)*. Vol. 37, págs. 360-369.
- Coward, S., J. Vann, S. Dunham y M. Stewart (2009). “The primary-response framework for geometallurgical variables”. En: *Seventh international mining geology conference*, págs. 109-113.
- Cropp, A. F., W. R. Goodall y D. J. Bradshaw (2013). “The influence of textural variation and gangue mineralogy on recovery of copper by flotation from porphyry ore—a review”. En: *The Second AusIMM International Geometallurgy Conference*. Vol. 30, págs. 279-291.
- Cruz, C., J. Ramos, P. Robles, W. H Leiva, R. I. Jeldres y L. A. Cisternas (2020). “Partial seawater desalination treatment for improving chalcopyrite floatability and tailing flocculation with clay content”. En: *Minerals Engineering* 151, pág. 106307. DOI: 10.1016/j.mineng.2020.106307
- Del Castillo, M. F. y R. Dimitrakopoulos (2016). “A multivariate destination policy for geometallurgical variables in mineral value chains using coalition-formation clustering”. En: *Resources Policy* 50, págs. 322-332. DOI: 10.1016/j.resourpol.2016.10.003
- Deutsch, CV (2013). “Geostatistical modelling of geometallurgical variables—Problems and solutions”. En: *Proceedings of the International Geometallurgy Conference, Brisbane, Australia*. Vol. 30

- Diaz, E., G. Pamparana, L. Voisin, W. Kracht y P. Martínez (2019). “Exploring the effect of the geological texture at meso and micro scale on grinding performance”. En: *Minerals Engineering* 144, pág. 106032. DOI: 10.1016/j.mineng.2019.106032
- Dimitrakopoulos, R. (1998). “Conditional simulation algorithms for modelling orebody uncertainty in open pit optimisation”. En: *International journal of surface mining, reclamation and environment* 12.4, págs. 173-179.
- Dimitrakopoulos, R. (2011). “Stochastic optimization for strategic mine planning: a decade of developments”. En: *Journal of Mining Science* 47.2, págs. 138-150. DOI: 10.1134/S1062739147020018
- Dimitrakopoulos, R. (2018). “Stochastic mine planning—methods, examples and value in an uncertain world”. En: *Advances in Applied Strategic Mine Planning*. Springer, págs. 101-115. DOI: 10.1007/978-3-319-69320-0\_9
- Dimitrakopoulos, R., C. T. Farrelly y M. Godoy (2002). “Moving forward from traditional optimization: grade uncertainty and risk effects in open-pit design”. En: *Mining Technology* 111.1, págs. 82-88. DOI: 10.1179/mnt.2002.111.1.82
- Dimitrakopoulos, R y S Ramazan (2004). “Uncertainty based production scheduling in open pit mining”. En: *SME transactions* 316.
- Dominy, S. C., L. O'Connor, A. Parbhakar-Fox, H. J. Glass y S. Purevgerel (2018). “Geometallurgy—A route to more resilient mine operations”. En: *Minerals* 8.12, pág. 560. DOI: 10.3390/min8120560
- Dowd, P. A., C. Xu y S. Coward (2016). “Strategic mine planning and design: some challenges and strategies for addressing them”. En: *Mining Technology* 125.1, págs. 22-34. DOI: 10.1179/1743286315Y.0000000032
- Dunham, S. y J. Vann (2007). “Geometallurgy, geostatistics and project value—does your block model tell you what you need to know”. En: *Proceedings of the Project Evaluation Conference, Melbourne, Australia*, págs. 19-20.
- Eivazy, H. y H. Askari-Nasab (2012). “A mixed integer linear programming model for short-term open pit mine production scheduling”. En: *Mining Technology* 121.2, págs. 97-108. DOI: 10.1179/1743286312Y.0000000006
- Erickson, A. J. y J. T. Padgett (2011). “Geological Data Collection”. En: *SME mining engineering handbook* 1, págs. 145-171.
- Farrokhpay, S. y D. Bradshaw (2012). “Effect of clay minerals on froth stability in mineral flotation”. En: *A review, XXVI. IMPC, New Delhi, India, Paper* 313
- Farrokhpay, S., B. Ndlovu y D. Bradshaw (2016). “Behaviour of swelling clays versus non-swelling clays in flotation”. En: *Minerals Engineering* 96, págs. 59-66. DOI: 10.1016/j.mineng.2016.04.011
- Fullston, D., D. Fornasiero y J. Ralston (1999). “Zeta potential study of the oxidation of copper sulfide minerals”. En: *Colloids and Surfaces A: Physicochemical and Engineering Aspects* 146.1-3, págs. 113-121. DOI: 10.1016/S0927-7757(98)00725-0
- Garrido, M., E. Sepúlveda y F. Navarro (2017). “Optimization of planning and orebody scheduling with open pit extraction using homogeneity of clays as geometallurgical variables”. En
- Gholamnejad, J. (2008). “A zero-one integer programming model for open pit mining sequences”. En: *Journal of the Southern African Institute of Mining and Metallurgy* 108.12, págs. 759-762.
- Hustrulid, W. A., M. Kuchta y R. K. Martin (2013). “Production Planning”. En: *Open pit mine planning and design* Vol. 1.

- Jamshidi, M. y M. Osanloo (2018). “Multiple destination influence on production scheduling in multi-element mines”. En: *International Journal of Engineering* 31.1, págs. 173-180. DOI: 10.5829/ije.2018.31.01a.23
- Kumar, A. y R. Dimitrakopoulos (2019). “Application of simultaneous stochastic optimization with geometallurgical decisions at a copper–gold mining complex”. En: *Mining Technology*. DOI: 10.1080/25726668.2019.1575053
- Kumral, M. (2015). “Grade control in multi-variable ore deposits as a quality management problem under uncertainty”. En: *International Journal of Quality & Reliability Management*. DOI: 10.1108/IJQRM-08-2013-0134
- Laurich, R. y B. Kennedy (1990). “Planning and design of surface mines”. En: *Surface Mining* 5, págs. 465-469.
- Leite, A. y R. Dimitrakopoulos (2007). “Stochastic optimisation model for open pit mine planning: application and risk analysis at copper deposit”. En: *Mining Technology* 116.3, págs. 109-118. DOI: 10.1179/174328607X228848
- Leite, A. y R. Dimitrakopoulos (2014). “Stochastic optimization of mine production scheduling with uncertain ore/metal/waste supply”. En: *International Journal of Mining Science and Technology* 24.6, págs. 755-762. DOI: 10.1016/j.ijmst.2014.10.004
- Lerchs, H. e I. F. Grossmann (1965). “Optimum design of open-pit mines”. En: *Transactions, CIM* 68, págs. 17-24.
- Lund, C. y P. Lamberg (2014). “Geometallurgy—A tool for better resource efficiency”. En: *European geologist* 37, págs. 39-43.
- McKay, N., J. Vann, W. Ware, C. Morley y P. Hodkiewicz (2016). “Strategic and Tactical Geometallurgy - a Systematic Process to Add and Sustain Resource Value”. En: *Proceedings of the 3rd Ausimm Geometallurgy Conference*, págs. 29-36.
- Montiel, L. y R. Dimitrakopoulos (2015). “Optimizing mining complexes with multiple processing and transportation alternatives: An uncertainty-based approach”. En: *European Journal of Operational Research* 247.1, págs. 166-178. DOI: 10.1016/j.ejor.2015.05.002
- Morales, N., S. Seguel, A. Cáceres, E. Jélvez y M. Alarcón (2019). “Incorporation of geometallurgical attributes and geological uncertainty into long-term open-pit mine planning”. En: *Minerals* 9.2, pág. 108. DOI: 10.3390/min9020108
- Navarra, A., T. Grammatikopoulos y K. Waters (2018b). “Incorporation of geometallurgical modelling into long-term production planning”. En: *Minerals Engineering* 120, págs. 118-126, DOI: 10.1016/j.mineng.2018.02.010
- Navarra, A., A. Menzies, A. Jordens y K. Waters (2017). “Strategic evaluation of concentrator operational modes under geological uncertainty”. En: *International Journal of Mineral Processing* 164, págs. 45-55. DOI: 10.1016/j.minpro.2017.05.009
- Navarra, A., L. Montiel y R. Dimitrakopoulos (2018a). “Stochastic strategic planning of open-pit mines with ore selectivity recourse”. En: *International Journal of Mining, Reclamation and Environment* 32.1, págs. 1-17. DOI: 10.1080/17480930.2016.1201380
- Ndlovu, B., S. Farrokhpay y D. Bradshaw (2013). “The effect of phyllosilicate minerals on mineral processing industry”. En: *International Journal of Mineral Processing* 125, págs. 149-156. DOI: 10.1016/j.minpro.2013.09.011
- Ndlovu, B., E. Forbes, S. Farrokhpay, M. Becker, D. Bradshaw y D. Deglon (2014). “A preliminary rheological classification of phyllosilicate group minerals”. En: *Minerals Engineering* 55, págs. 190-200. DOI: 10.1016/j.mineng.2013.06.004

- Nelis, G. y N. Morales (2017). "Effect of information on the short-term scheduling in an open pit mine". En: *Proceedings of the 5th International Seminar on Geology for the Mining Industry, Geomin 2017*, págs. 95-105.
- Nelis, G. y N. Morales (2021a). "A mathematical model for the scheduling and definition of mining cuts in short-term mine planning". En: *Optimization and Engineering* 23.1, págs. 233-257. DOI: 10.1007/s11081-020-09580-1
- Nelis, G. y N. Morales (2021c). "A comparison of mining cut definition and scheduling algorithms for open-pit short-term mine planning". En: *INTERNATIONAL SYMPOSIUM ON THE APPLICATION OF COMPUTERS AND OPERATIONS RESEARCH IN THE MINERAL INDUSTRY (APCOM)*, págs. 55-67.
- Nelis, G., N. Morales y E. Widzyk-Capehart (2018). "Comparison of different approaches to strategic open-pit mine planning under geological uncertainty". En: *Proceedings of the 27th International Symposium on Mine Planning and Equipment Selection-MPES 2018*. Springer, págs. 95-105. DOI: 10.1007/978-3-319-99220-4\_8
- Nelis, Gonzalo, Frédéric Meunier y Nelson Morales (2021b). "Column Generation for Mining Cut Definition with Geometallurgical Interactions". En: *Natural Resources Research* 31.1, págs. 131-148
- Neufeld, C. T., K. P. Norrena y C. V. Deutsch (2003). "Semi-automatic dig limit generation". En: *Proceedings of the 5th Centre for Computational Geostatistics Annual Conference. University of Alberta, AB, Canada*
- Newman, A., E. Rubio, R. Caro, A. Weintraub y K. Eurek (2010). "A review of operations research in mine planning". En: *Interfaces* 40.3, págs. 222-245. DOI: 10.1287/inte.1090.0492
- Norrena, K. P. y C. V. Deutsch (2001). "Automatic Determination of Dig Limits Subject to Geostatistical, Economic and Equipment Constraints". En: *Centre for Computational Geostatistics Report 3 - 114*
- Norrena, K. P., C. Neufeld y C. V. Deutsch (2002). "An update on automatic dig limit determination". En: *Department of Civil & Environmental Engineering, University of Alberta. Retrieved April 7, págs. 2015.*
- Osanloo, M., J. Gholamnejad y B. Karimi (2008). "Long-term open pit mine production planning: a review of models and algorithms". En: *International Journal of Mining, Reclamation and Environment* 22.1, págs. 3-35
- Rahmanpour, M. y M. Osanloo (2016). "Resilient decision making in open pit short-term production planning in presence of geologic uncertainty". En: *International Journal of Engineering* 29.7, págs. 1022-1028.
- Rehman, Safi Ur y Mohammad Waqar Ali Asad (2010). "A mixed-integer linear programming (milp) model for short-range production scheduling of cement quarry operations". En: *Asia-Pacific journal of operational research* 27.03, págs. 315-333. DOI: 10.1142/S0217595910002727
- Ruiseco, J. R., J. Williams y M. Kumral (2016). "Optimizing ore-waste dig-limits as part of operational mine planning through genetic algorithms". En: *Natural Resources Research* 25.4, págs. 473-485. DOI: 10.1007/s11053-016-9296-1
- Sari, Y. A. y M. Kumral (2017). "Dig-limits optimization through mixed-integer linear programming in open-pit mines". En: *Journal of the operational research society* 69.2, págs. 171-182. DOI: 10.1057/s41274-017-0201-z

- Tabesh, M. y H. Askari-Nasab (2011). “Two-stage clustering algorithm for block aggregation in open pit mines”. En: *Mining Technology* 120.3, págs. 158-169. DOI: 10.1179/1743286311Y.0000000009
- Tabesh, M. y H. Askari-Nasab (2013). “Automatic creation of mining polygons using hierarchical clustering techniques”. En: *Journal of Mining Science* 49.3, págs. 426-440. DOI: 10.1134/S1062739149030106
- Tabesh, M. y H. Askari-Nasab (2019). “Clustering mining blocks in presence of geological uncertainty”. En: *Mining Technology*. DOI: 10.1080/25726668.2019.1596425
- Tabesh, M., C. Mieth y H. Askari-Nasab (2014). “A multi-step approach to long-term open-pit production planning”. En: *International Journal of Mining and Mineral Engineering* 5.4, págs. 273-298. DOI: 10.1504/IJMME.2014.066577
- Tungpalan, K., E. Wightman y E. Manlapig (2015). “Relating mineralogical and textural characteristics to flotation behaviour”. En: *Minerals Engineering* 82, págs. 136-140. DOI: 10.1016/j.mineng.2015.02.005
- U.S.G.S. (2021). *Mineral commodity summaries 2021*.
- Vallee, M (2000). “Mineral resource+ engineering, economic and legal feasibility= ore reserve”. En: *CIM bulletin* 93.1038, págs. 53-61.
- Villalba, M. E. y R. Dimitrakopoulos (2016). “Stochastic short-term mine production schedule accounting for fleet allocation, operational considerations and blending restrictions”. En: *European Journal of Operational Research* 255.3, págs. 911-921. DOI: 10.1016/j.ejor.2016.05.050
- Whittle, D. (2011). “Open-pit planning and design”. En: *SME mining engineering handbook* 1, págs. 877-901.
- Yarmuch, J. (2021). *Planificación Minera*. Apuntes de curso. Departamento de Ingeniería de Minas, Facultad de Ciencias Físicas y Matemáticas, Universidad de Chile.
- Zhao, S. e Y. Peng (2012). “The oxidation of copper sulfide minerals during grinding and their interactions with clay particles”. En: *Powder technology* 230, págs. 112-117, DOI: 10.1016/j.powtec.2012.07.016
- Zhou, Z (1997). “Swelling clays in hydrocarbon reservoir: the bad, the less bad, and the useful”. En

# Anexos



# Anexo A

## Determinista y Conocimiento Parcial




Figura A.1: Ubicación bloques representantes de Prueba 1.




Figura A.2: Ubicación bloques representantes de Prueba 3.




Figura A.3: Ubicación bloques representantes de Prueba 4.




Figura A.4: Ubicación bloques representantes de Prueba 7 y 8.




Figura A.5: Gráfico de VPN determinista para un radio 6.




Figura A.6: Gráfico de VPN de conocimiento parcial para un radio 6.




Figura A.7: Gráfico de VPN determinista para un radio 7.




Figura A.8: Gráfico de VPN de conocimiento parcial para un radio 7.




Figura A.9: Gráfico de VPN determinista para un radio 10.




Figura A.10: Gráfico de VPN de conocimiento parcial para un radio 10.

Tabla A.1: Resumen de resultados de Prueba 1 y Radio 12.

	Promedio [MUSD]	Máximo		Mínimo		Diferencia	
		VPN [MUSD]	Escenario	VPN [MUSD]	Escenario	Total [MUSD]	Promedio [MUSD]
R=12 DET	5.96	6.03	1	5.92	17		
R=12 CPAR	5.98	6.05	7	5.90	17	0.28	0.01

Tabla A.2: Resumen de resultados de Prueba 2.

	Promedio [MUSD]	Máximo		Mínimo		Diferencia	
		VPN [MUSD]	Escenario	VPN [MUSD]	Escenario	Total [MUSD]	Promedio [MUSD]
R=6 DET	5.92	5.97	18	5.85	4		
R=6 CPAR	5.94	6.00	7	5.87	4	0.31	0.01
R=7 DET	5.94	5.99	7	5.85	8		
R=7 CPAR	5.94	6.00	7	5.87	4	-0.01	<-0.01
R=10 DET	5.94	5.99	7	5.85	8		
R=10 CPAR	5.94	6.00	16	5.86	4	0.13	0.01

Tabla A.3: Resumen de resultados de Prueba 4.

	Promedio [MUSD]	Máximo		Mínimo		Diferencia	
		VPN [MUSD]	Escenario	VPN [MUSD]	Escenario	Total [MUSD]	Promedio [MUSD]
R=6 DET	5.97	6.04	7	5.90	17		
R=6 CPAR	5.97	6.05	7	5.90	4	0.16	0.01
R=7 DET	5.98	6.05	7	5.91	8		
R=7 CPAR	6.00	6.10	7	5.94	4	0.42	0.02
R=10 DET	6.03	6.09	16	5.95	4		
R=10 CPAR	6.03	6.11	1	5.95	8	0.11	0.01

Tabla A.4: Resumen de resultados de Prueba 5.

	Promedio [MUSD]	Máximo		Mínimo		Diferencia	
		VPN [MUSD]	Escenario	VPN [MUSD]	Escenario	Total [MUSD]	Promedio [MUSD]
R=6 DET	6.11	6.16	1	6.02	8		
R=6 CPAR	6.12	6.19	1	6.04	8	0.15	0.01
R=7 DET	6.12	6.18	16	6.02	4		
R=7 CPAR	6.13	6.20	16	6.05	8	0.11	0.01
R=10 DET	6.10	6.16	16	6.00	8		
R=10 CPAR	6.13	6.18	1	6.05	8	0.63	0.03

Tabla A.5: Resumen de resultados de Prueba 8.

	Promedio [MUSD]	Máximo		Mínimo		Diferencia	
		VPN [MUSD]	Escenario	VPN [MUSD]	Escenario	Total [MUSD]	Promedio [MUSD]
R=6 DET	6.10	6.17	16	6.03	8	0.52	0.02
R=6 CPAR	6.13	6.21	16	6.04	8		
R=7 DET	6.11	6.17	7	6.03	8	0.36	0.02
R=7 CPAR	6.12	6.19	7	6.04	8		
R=10 DET	6.11	6.17	7	6.01	8	0.43	0.02
R=10 CPAR	6.13	6.20	7	6.07	4		

Tabla A.6: Resumen de resultados de Prueba 10.

	Promedio [MUSD]	Máximo		Mínimo		Diferencia	
		VPN [MUSD]	Escenario	VPN [MUSD]	Escenario	Total [MUSD]	Promedio [MUSD]
R=6 DET	6.10	6.16	1	6.02	8	0.32	0.02
R=6 CPAR	6.12	6.20	16	6.05	8		
R=7 DET	6.10	6.16	16	6.01	8	0.40	0.02
R=7 CPAR	6.12	6.19	7	6.06	4		
R=10 DET	6.10	6.15	1	6.00	8	0.83	0.04
R=10 CPAR	6.13	6.20	16	6.03	8		

Tabla A.7: Promedio de tonelaje por destino y radio para el caso CPAR.

	Planta de Óxidos [ton]	Planta de Sulfuros [ton]
R=6	140,185.71	210,814.29
R=7	137,915.36	213,084.64
R=10	138,045.86	213,931.29




Figura A.11: Ocupación de planta de óxidos de para radio 6.




Figura A.12: Ocupación de planta de óxidos de para radio 7.




Figura A.13: Ocupación de planta de sulfuro de para radio 7.




Figura A.14: Ocupación de planta de sulfuro de para radio 10.



# Anexo B

## Conocimiento Perfecto

Tabla B.1: Resumen de resultados de Prueba 11.

		Máximo		Mínimo	
	Promedio [MUSD]	Valor [MUSD]	Escenario	Valor [MUSD]	Escenario
<b>R=6</b>	6.17	6.23	7	6.09	8
<b>R=7</b>	6.17	6.23	7	6.09	8
<b>R=10</b>	6.17	6.23	7	6.09	8

Tabla B.2: Resumen de resultados de Prueba 14.

		Máximo		Mínimo	
	Promedio [MUSD]	VPN [MUSD]	Escenario	VPN [MUSD]	Escenario
<b>R=6</b>	6.17	6.22	16	6.10	8
<b>R=7</b>	6.17	6.21	7	6.08	8
<b>R=10</b>	6.17	6.22	7	6.09	8

Tabla B.3: Resumen de resultados de Prueba 15.

		Máximo		Mínimo	
	Promedio [MUSD]	VPN [MUSD]	Escenario	VPN [MUSD]	Escenario
<b>R=8</b>	5.89	5.94	16	5.81	17
<b>R=10</b>	5.95	6.02	16	5.88	4




Figura B.1: Gráfico de VPN de conocimiento perfecto de radio 6.




Figura B.2: Gráfico de VPN de conocimiento perfecto de radio 7.




Figura B.3: Gráfico de VPN de conocimiento perfecto de radio 10.




Figura B.4: Gráfico de VPN de conocimiento perfecto de pruebas 11 y 12.




Figura B.5: Gráfico de VPN de conocimiento perfecto de pruebas 13 y 14.




Figura B.6: Gráfico de VPN de conocimiento perfecto de pruebas 15 y 16.

Tabla B.4: Promedio de tonelaje por destino y radio para el caso CP.

	Planta de Óxidos [ton]	Planta de Sulfuros [ton]
<b>R=6</b>	136,261.61	214,738.39
<b>R=7</b>	135,980.36	215,019.64
<b>R=10</b>	131,683.93	219,316.07




Figura B.7: Ocupación de planta de óxidos CP de para radio 6.




Figura B.8: Ocupación de planta de óxidos CP de para radio 7.




Figura B.9: Ocupación de planta de sulfuro CP de para radio 7.




Figura B.10: Ocupación de planta de sulfuro CP de para radio 10.

# Anexo C

## Recuperación Variable




Figura C.1: Gráfico de valor económico de pruebas de conocimiento parcial con recuperación variable.




Figura C.2: Gráfico de valor económico de pruebas de conocimiento perfecto con recuperación variable.

Tabla C.1: Promedio de tonelaje por destino y radio para con recuperación variable.

	Planta de Óxidos [ton]	Planta de Sulfuros [ton]
<b>CPAR</b>	125,569.29	225,430.71
<b>CP</b>	121,387.50	229,612.50




Figura C.3: Ocupación de planta de óxidos de CPAR con recuperación variable.




Figura C.4: Ocupación de planta de sulfuros de CPAR con recuperación variable.