



Machine learning - Lisheen

Un nuevo proceso de modelado de dominio geológico Maptek™ que emplea el Machine Learning ha proporcionado formas y volúmenes precisos en un tiempo mucho más corto.

La mina Lisheen, ubicada en la región central de Irlanda en el condado de Tipperary, apareció en Maptek Forge en diciembre de 2001. La mina de zinc y plomo alojada en carbonato estaba en pleno funcionamiento en ese momento

utilizando el software Maptek Vulcan para prospección subterránea, modelado geológico, variografía, estimación de recursos, y planificación minera.

La mina entró en producción en septiembre de 1999 y produjo un promedio de aproximadamente 160,000 toneladas por año de contenido zinc en concentrado y 25,000 toneladas por año de contenido plomo en concentrado.

La mina estaba agotada de mineral en 2015 y esta retrospectiva compara el modelado geológico utilizado durante la minería, con el modelado utilizando el servicio de Machine Learning Maptek de nueva generación.

El sector de arriendo de la mina Lisheen incluye un total de 2700 perforaciones superficiales y 4670 subterráneas (ver Figura 1). La perforación fue predominantemente un núcleo de perforación de diamante y fue registrada en detalle por geólogos mineros. Los tipos de rocas se clasificaron en 50 códigos diferentes durante el registro y se utilizaron para el modelado de dominio posterior.

No se registra cuánto tiempo se tardó en generar los wireframes para representar estos códigos geológicos. Sería seguro asumir que se necesitaron muchas semanas para modelar la interacción compleja de algunas de estas unidades.

Maptek ha desarrollado un nuevo proceso de modelado de dominio geológico utilizando Machine Learning, que es especialmente adecuado para grandes volúmenes de datos. Los datos del sector de arriendo de la mina Lisheen se ingresaron en el motor de Machine Learning para el procesamiento junto con las dimensiones del modelo de bloque resultante, en el que se escriben los dominios directamente.

No se utilizaron otras interpretaciones geológicas, aparte de los códigos de roca en la base de perforación para el procesamiento. Se usó un tamaño de

bloque principal de 12x12x4m con tamaños de subceldas de hasta 3x3x1m para los cuerpos de mineral subhorizontales.

Después de 50 minutos de procesamiento, el modelo de bloque de recursos se completó, marcado con dominios generados para los 50 códigos de roca.

La diferencia registrada en los volúmenes de mineral entre los métodos fue solo del 4%, y el nuevo enfoque fue mucho más rápido.

El modelo de bloques se validó visualmente mediante secciones transversales y secciones largas que comparan códigos de perforación y los códigos de geología de bloques. Estos se compararon muy favorablemente como se puede ver en la Figura 2.

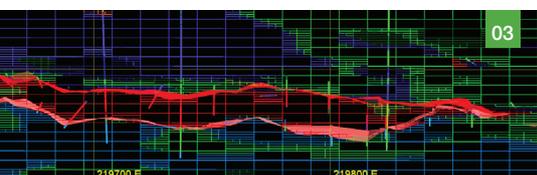
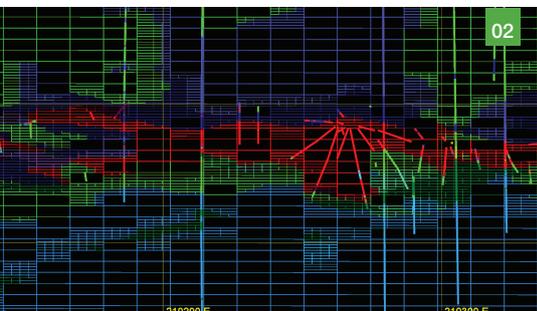
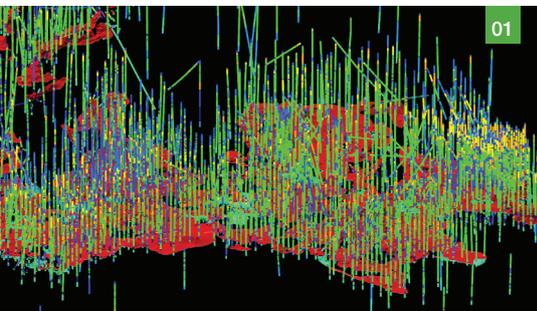
Luego de la comparación de los dominios de Machine Learning con los códigos de perforación originales, se llevó a cabo una verificación de las estructuras manuales generadas durante la operación de la mina. Esto también mostró una coincidencia muy estrecha como se puede ver en la Figura 3.

Luego se realizó una comparación volumétrica entre el modelo de recursos de la mina utilizando estructuras de alambre manuales para marcar dominios geológicos y el modelo construido utilizando el Machine Learning.

En resumen, solo hubo una diferencia del 4% en los volúmenes de mineral entre los métodos, lo cual es una comparación muy favorable.

El modelo de Machine Learning creado a partir de los códigos interpretados en la base de datos de perforación, sin más intervención geológica, ha sido capaz de replicar con precisión las formas y volúmenes del dominio geológico.

Agradecimientos a Minerals Ireland por el acceso a los datos de la mina Lisheen.



01 Vista en perspectiva de la perforación superficial y subterránea en Lisheen con mineral de sulfuro masivo que se muestra en rojo

02 Corte a través del modelo de recursos de una de las zonas de sulfuro masivas (rojo) que indica muestras de perforación y los límites del dominio geológico generados por el Machine Learning (bloques rojos)

03 Estrecha correlación entre la estructura metálica manual (rojo = superficie superior, rosa = superficie inferior) en comparación con los bloques en la zona de mineral (rojo) determinados por el Machine Learning.