



ARTÍCULO ESPECIAL

Bioinformática y gestión de datos ómicos en diagnóstico genético

Angela del Pozo

Instituto de Genética Médica y Molecular (INGEMM); IdiPAZ, Hospital Universitario La Paz, Madrid, España

Recibido el 17 de septiembre de 2024; aceptado el 4 de agosto de 2025

PALABRAS CLAVE

Bioinformática clínica;
NGS;
Secuenciación;
Genética molecular;
Genómica;
Ómicas;
Análisis de datos;
Enfermedades raras

Resumen La secuenciación de nueva generación (NGS) abarca una gama de tecnologías que han transformado la investigación genómica desde los años 2000. Al permitir la secuenciación de grandes fragmentos de ADN a un costo significativamente menor que la secuenciación de Sanger, la NGS se ha convertido en una herramienta indispensable en los laboratorios moleculares, particularmente en el campo de la genética molecular. Su alta eficiencia y rapidez la convierten en una tecnología de primera línea en el análisis genético.

Un paso crucial para lograr un diagnóstico es el análisis bioinformático. La tecnología de secuenciación de lectura corta genera datos en bruto que deben ser procesados para extraer información significativa e interpretable. Este proceso permite la identificación de vínculos causales entre los hallazgos genéticos y los rasgos fenotípicos. Expertos en Bioinformática Clínica realizan este análisis utilizando herramientas especializadas y *pipelines*, que tienen en cuenta las características específicas de las plataformas de secuenciación, los protocolos y las enfermedades particulares que se están estudiando.

La revisión de calidad es un complemento esencial del análisis de las *pipelines*. Su objetivo principal es evaluar qué muestras son adecuadas para el diagnóstico y, en casos donde los resultados son negativos, identificar las razones, ya sean relacionadas con la incidencia u otros factores. Además, la revisión de calidad ofrece información sobre la efectividad general de los procedimientos experimentales.

A pesar de sus muchas ventajas, la NGS aún enfrenta varios desafíos, como la necesidad de tecnologías más eficientes, marcos regulatorios mejorados y una mejor capacitación para el personal médico.

© 2025 Asociación Española de Pediatría. Publicado por Elsevier España, S.L.U. Este es un artículo Open Access bajo la licencia CC BY-NC-ND (<http://creativecommons.org/licenses/by-nc-nd/4.0/>).

Correo electrónico: angela.pozo@salud.madrid.org

<https://doi.org/10.1016/j.anpedi.2025.504013>

1695-4033/© 2025 Asociación Española de Pediatría. Publicado por Elsevier España, S.L.U. Este es un artículo Open Access bajo la licencia CC BY-NC-ND (<http://creativecommons.org/licenses/by-nc-nd/4.0/>).

KEYWORDS

Clinical
bioinformatics;
NGS;
Sequencing;
Molecular genetics;
Genomics;
Omics;
Data analysis;
Rare diseases

Bioinformatics and omics data management in genetic diagnosis

Abstract Next Generation Sequencing (NGS) encompasses a range of technologies that have transformed genomic research since the 2000s. By allowing the sequencing of large DNA fragments at a significantly lower cost than Sanger sequencing, NGS has become an indispensable tool in molecular laboratories, particularly in the field of molecular genetics. Its high efficiency and speed make it a first-line technique in genetic analysis.

A crucial step in achieving a diagnosis is bioinformatics analysis. Short-read sequencing technology generates raw data that must be processed to extract meaningful and interpretable information. This process enables the identification of causal links between genetic findings and phenotypic traits. Clinical bioinformatics specialists carry out this analysis using specialized tools and *pipelines*, which take into account the specific characteristics of the sequencing platforms, protocols and the particular diseases under study.

The quality review is an essential complement to the pipeline analysis. Its primary objective is to assess which samples are suitable for diagnosis and, in cases where results are negative, to identify the reasons, whether they are related to the incidence or other factors. Additionally, the quality review offers insight into the overall effectiveness of the experimental procedures.

Despite its many advantages, NGS still faces several challenges, including the need for more efficient technologies, enhanced regulatory frameworks and improved training of medical staff. © 2025 Asociación Española de Pediatría. Published by Elsevier España, S.L.U. This is an open access article under the CC BY-NC-ND license (<http://creativecommons.org/licenses/by-nc-nd/4.0/>).

Introducción

Next Generation Sequencing (NGS) es un término que engloba diversas tecnologías para secuenciar ADN¹, revolucionando la investigación genómica desde los años 2000, al permitir la resolución de grandes regiones de ADN a menor coste y tiempo que la secuenciación Sanger. La NGS se ha convertido en una herramienta esencial en los laboratorios moleculares, siendo una tecnología de primera línea por su alto rendimiento y rapidez.

A día de hoy la NGS se emplea en diversos contextos clínicos, aunque con una implantación desigual. Además de su uso en Genética Molecular, está presente en Oncología, Microbiología, Inmunología, Hematología y Salud Pública.

Las plataformas de NGS se dividen en dos grandes categorías: las de lectura corta, que secuencian fragmentos de 100 a 300 pares de bases², y las de última generación³ (o lectura larga), que pueden leer fragmentos de hasta 100.000 pares de bases, como las de *Pacific Biosciences* y *Oxford Nanopore Technologies*. En el entorno clínico, las plataformas Illumina, de lectura corta, son las más utilizadas y sus *workflows* se consideran un estándar de facto.

En Genética Molecular, los datos de secuenciación de lectura corta deben ser procesados para convertirlos en información útil e interpretable, permitiendo identificar relaciones causales entre hallazgos y fenotipos, y facilitando el manejo clínico del paciente cuando se identifican resultados clínicamente accionables. El análisis de los datos debe ser realizado por especialistas en Bioinformática Clínica con herramientas específicas, considerando las particularidades de las plataformas, los protocolos de secuenciación y las patologías estudiadas. Este análisis se realiza mediante plataformas de análisis o *pipelines*.

En los últimos años, diversos consorcios han aportado información y recursos valiosos que han permitido conocer en mayor profundidad el perfil de las variaciones, tanto de individuos sanos⁴ como de pacientes⁵, mejorando la interpretabilidad de los resultados obtenidos con la NGS.

Sin embargo, la secuenciación masiva, dentro del ámbito diagnóstico, se enfrenta a diversos desafíos^{6,7} técnicos y metodológicos, como la necesidad de plataformas de secuenciación más eficientes, algoritmos bioinformáticos optimizados, mejoras en la regulación y control de calidad, así como una mayor capacitación del personal médico.

Los próximos apartados abordarán estos aspectos para proporcionar una comprensión completa de la NGS y el estatus actual de otras tecnologías ómicas con fines diagnósticos.

Las tecnologías ómicas y su introducción en la práctica clínica

Las tecnologías ómicas son un conjunto de técnicas que se utilizan para estudiar de manera integral todos los agentes que participan en los procesos moleculares de los seres vivos.

Todas comparten la característica de que generan un volumen masivo de datos que debe analizarse mediante metodologías complejas de base estadística. Además, requieren infraestructuras con gran capacidad de cómputo, recursos para el almacenamiento y gestión de la información, y personal especializado para su análisis y gobernanza.

En el contexto diagnóstico, las ómicas más comunes son la Genómica, la Transcriptómica, la Proteómica, la Metabólica y la Epigenómica.

De todas ellas, son las tecnologías genómicas (las que analizan el ADN de los individuos, como la NGS) las que tienen una mayor presencia en la rutina clínica. Respecto al

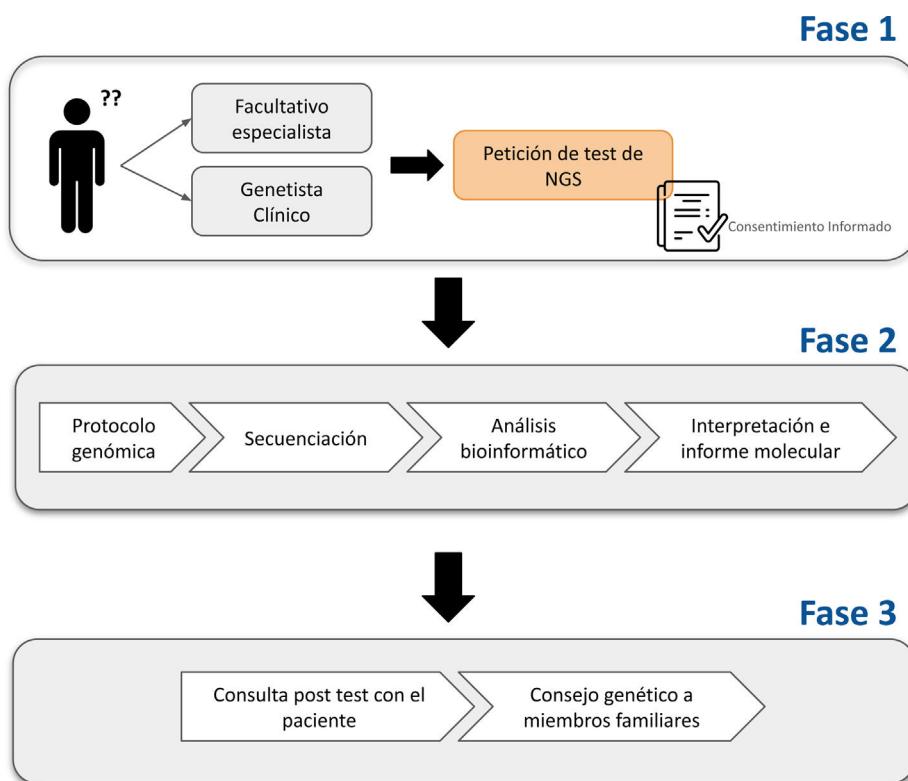


Figura 1 Diagrama del flujo de trabajo en un test de NGS.

Se muestran las fases necesarias para realizar un test de NGS: inicialmente el paciente acude a consulta y el médico peticionario (facultativo especialista o genetista clínico) solicita una prueba de NGS, previa firma del consentimiento informado (fase 1). Posteriormente se realiza el proceso del test de manera secuencial (fase 2) para que, finalmente, los resultados del informe molecular sean comunicados en consulta, y, si es necesario, se ofrecerá asesoramiento genético a los familiares (fase 3).

resto, en la mayoría de los casos su uso se circunscribe a proyectos de investigación que buscan como último fin su implantación en la clínica. Más adelante se detallan algunos ejemplos de estos usos.

La secuenciación masiva como técnica diagnóstica

La NGS tiene un estatus de test diagnóstico, y en la última década las pruebas moleculares basadas en esta tecnología se han incorporado en la cartera de servicios del sistema de salud español.

Actualmente, la implementación de la NGS sigue siendo desigual entre las comunidades autónomas, afectada por la necesidad de recursos tecnológicos y de personal bioinformático para garantizar la validez de los resultados.

Su introducción en laboratorios moleculares ha marcado un cambio de paradigma: antes, el personal técnico realizaba los experimentos y el facultativo emitía el informe. Ahora, la NGS exige un análisis de datos previo a la interpretación clínica, lo que obliga a los laboratorios a adaptarse a estas nuevas demandas.

Las principales particularidades que presenta la NGS como técnica diagnóstica se pueden resumir en: 1) su deslocalización, y 2) ausencia de puntos de autocontrol.

La deslocalización implica la ejecución de múltiples etapas de manera secuencial para obtener un resultado interpretable a nivel diagnóstico, pudiendo ser

realizadas por diferentes laboratorios o instituciones. Cada etapa demanda espacios específicos, recursos especializados y personal experto.

Este flujo de trabajo ([fig. 1](#)) comienza cuando el médico solicita la prueba (previa firma del consentimiento informado), continúa con la extracción de ADN del tejido de interés y la creación de librerías de fragmentos de ADN mediante protocolos estandarizados, seguido de la secuenciación en una plataforma de ultrasecuenciación, y culmina con el análisis bioinformático.

Posteriormente, el personal facultativo elabora un informe molecular donde se incluyen los hallazgos (positivos, negativos o no concluyentes) e información relevante sobre el test realizado.

La deslocalización permite que el test, o algunas de sus fases, puedan externalizarse, resultando en modelos de trabajo a) *in-house*; b) externalizados, o c) híbridos ([tabla 1](#)).

La fragmentación de subprocesos requiere protocolos de comunicación normalizados entre todas las partes que aseguren la trazabilidad y la correcta gestión del proceso diagnóstico. La supervisión y la monitorización del proceso son esenciales para garantizar la validez analítica y clínica del test⁸, incluso en modelos externalizados o híbridos.

La validez global del test depende fuertemente del proceso analítico, ya que es en el proceso bioinformático donde se van a detectar el grueso de incidencias, como cambios de muestra, contaminaciones, muestras de baja calidad, etc.,

Tabla 1 Modelos de implantación en el test de NGS

Modelos de test de NGS			
Tipo de modelo	Descripción	Pros	Contras
<i>in-house</i>	La institución asume por completo todas las fases del test, desde la realización experimental, el análisis bioinformático y la interpretación de datos	<ul style="list-style-type: none"> • Es un modelo flexible que permite adaptar los procesos a la cartera de servicios • Control sobre el proceso, detección de incidencias y posibilidad de medidas correctivas • Posibilidad de innovación y mejora técnica 	<ul style="list-style-type: none"> • Necesidad de incorporar RRHH especializados • Necesidad de adecuar las pipelines al Reglamento europeo • Costes asociados al mantenimiento de los equipos y recursos necesarios • Posibilidad de hacer explotación secundaria, debido al control sobre los datos
externalizado	La institución delega en un tercero para realizar de forma completa el test de NGS. Habitualmente, la extracción de ADN y la preparación experimental se asumen de manera interna	<ul style="list-style-type: none"> • Reducción de costes en la partida de RRHH • Reducción de costes en el mantenimiento de equipos Reducción de esfuerzos en la acreditación y certificación de los procesos 	<ul style="list-style-type: none"> • Falta de flexibilidad para incorporar mejoras adaptadas al contexto de la institución • Por limitaciones del RGPD, la información clínica del paciente es limitada y lastra la interpretación de los datos • La traza del proceso se pierde, dificultando la identificación de las muestras • Los informes pueden no adecuarse a la estandarización de la institución
híbrido	La institución delega en un tercero alguna de las fases del test de NGS. La situación más usual es que el análisis bioinformático es subcontratado a una empresa o se realiza con un software licenciado. En ese caso, la interpretación de los datos la asume la institución	<ul style="list-style-type: none"> • Las <i>pipelines</i> con licencia deben estar acreditadas • Reducción de esfuerzos en innovación a nivel de análisis • Reducción de costes en la contratación de bioinformático/as 	<ul style="list-style-type: none"> • La traza en la gestión de datos puede quedar interrumpida si los ficheros bioinformáticos no son facilitados por el tercero • En caso de no tener control sobre el dato, no es posible la explotación secundaria • Ante la ausencia de personal experto en Bioinformática, no es posible testar la bondad de los resultados entregados por un tercero • En algunos casos no es posible la detección de incidencias producidas en proceso experimental ni la identificación de muestras • Rigidez en los procesos analíticos, adaptados a ciertos casos de uso

Actualmente, en entornos hospitalarios, existen tres modelos diferentes de test de NGS: *in-house* (donde la institución asume todos los pasos del test), externalizado (donde se subcontrata el servicio a un tercero) o híbrido (cuando alguna de las fases del test se delega en un tercero). En la tabla se lista los aspectos a favor y en contra de cada uno de los modelos.

y se van a identificar finalmente qué muestras son aptas para el diagnóstico.

Sin embargo, uno de los desafíos de la NGS es la falta de puntos de autocontrol durante el proceso, más allá de los existentes en las plataformas de secuenciación. Esto es crítico, especialmente en la determinación de variantes, donde *pipelines* mal calibradas o con salidas primarias del secuenciador incompletas pueden generar archivos con información deficiente.

Además, la falta de buenas prácticas estandarizadas y la deslocalización entre laboratorios que participan de

una misma prueba dificultan la implementación de medidas correctivas que aseguren la calidad y la integridad del proceso. Esto resalta la importancia de adoptar marcos de calidad por parte de los laboratorios clínicos, como las normas ISO, para garantizar la seguridad del paciente. Estas cuestiones se abordarán más adelante.

Otro aspecto importante de la NGS es la posibilidad de realizar estudios dirigidos mediante paneles de genes asociados a enfermedades, enfocándose en regiones específicas del genoma reduciendo costes y tiempo de análisis. Así mismo, cuando se requieren análisis más amplios, es posible

secuenciar el exoma completo (WES) o el genoma completo (WGS).

Finalmente, debemos destacar la necesidad de gestión de un gran volumen de datos que se generan en cada test realizado. El tamaño por prueba varía en función de múltiples factores, como la extensión de la región secuenciada, el grado de amplificación (llamado profundidad de lecturas) y el número de muestras que se secuencian de manera conjunta.

Como referencia, se pueden consultar las especificaciones de la plataforma NovaSeq 6000 de Illumina⁹, que ofrece una visión general sobre la escala de los tamaños de archivo. La salida bruta del secuenciador varía entre 230 gigabyte (GB) y 3 terabyte (TB), mientras que un estudio completo, considerando todos los archivos generados tanto en la secuenciación como en el análisis, puede ocupar entre 560 GB y 6,5 TB.

Los datos de NGS deben ser tratados como datos médicos, al igual que la imagen médica u otra información clínica. Bajo esta perspectiva, y conforme a la Ley 41/2002 sobre la autonomía del paciente, su conservación debe garantizarse por un mínimo de 5 años.

Por ello, contar con una infraestructura de almacenamiento adecuada es fundamental, y requiere una planificación eficiente que asegure la custodia de los datos genómicos a medio plazo.

Otras ómicas aplicadas al diagnóstico

Además de la genómica, otras tecnologías ómicas están ganando relevancia en el ámbito clínico. Aunque ya se utilizan para el diagnóstico en algunos casos, su aplicación sigue siendo mayoritariamente preclínica.

Estas tecnologías juegan un papel clave en el descubrimiento, el análisis y la validación de nuevas terapias, biomarcadores y herramientas diagnósticas, fundamentales para el avance de la medicina personalizada.

La proteómica, que analiza a gran escala la presencia de proteínas en una muestra, ha experimentado avances significativos en los últimos años gracias a mejoras técnicas y análisis bioinformáticos más efectivos¹⁰. Un ejemplo destacado es el test Overa, desarrollado por Vermillion, Inc., que utiliza espectrometría de masas en tandem (LC-MS/MS) para evaluar el riesgo de cáncer de ovario en mujeres con masas pélvicas. Este test recibió la aprobación de la FDA en 2016.

El estudio de metabolitos es conocido en medicina pediátrica, especialmente en el cribado neonatal de errores congénitos del metabolismo. La metabolómica representa un avance relevante al permitir el análisis no dirigido de miles de metabolitos, facilitando la identificación de firmas metabólicas en fluidos y tejidos. Actualmente se investiga su aplicación en diversas patologías, como la diabetes tipo 2, donde la detección temprana podría mejorar el pronóstico de los pacientes¹¹.

Otro ámbito de interés es la oncología de precisión, donde es clave poder establecer biomarcadores para la detección precoz, la clasificación tumoral y la respuesta a tratamientos. En este sentido, el análisis del epigenoma está aportando casos de éxito como el uso de mutaciones activadoras de EGFR como biomarcadores, lo que

ha mejorado significativamente la supervivencia de los pacientes con cáncer de pulmón de células no pequeñas (NSCLC)¹².

En el ámbito de la Genética Molecular hay que destacar las metodologías de integración (llamadas también «multiómicas»), que permiten fusionar información para mejorar el diagnóstico de pacientes cuyo mecanismo causal no ha sido identificado a pesar de mostrar fenotipos característicos.

Así, la inclusión de muestras de RNA-Seq en estudios moleculares permite analizar el transcriptoma del paciente, facilitando la identificación de alteraciones en la maquinaria de *splicing* y la detección de genes con expresión aberrante¹³.

El estudio de la firma epigenética¹⁴ está mostrando también su utilidad en pacientes con enfermedades del neurodesarrollo, ya que permite la clasificación de pacientes con una manifestación sindrómica compleja o con fenotipos similares, como el síndrome de Kabuki y el síndrome de CHARGE, mejorando la precisión en el diagnóstico.

Análisis de datos de NGS: *pipelines* bioinformáticas

Llamamos *pipeline* bioinformática al conjunto de herramientas y algoritmos que analizan la salida bruta de las plataformas de secuenciación e identifican las variantes genéticas que porta el paciente. El término técnico *pipeline* se emplea ampliamente en los laboratorios de diagnóstico, al igual que otros conceptos propios de la Bioinformática que han sido adoptados sin necesidad de traducción; por ello, los usaremos de este modo a lo largo del texto.

Las *pipelines* suelen integrar herramientas de software libre y código abierto, aunque también existen versiones bajo licencia o que incorporan herramientas comerciales como complemento.

Las *pipelines* deben estar adaptadas al tipo de variante y su origen (germinal o somático), lo que exige metodologías específicas para cada caso.

En línea germinal, las variantes que usualmente se caracterizan son: 1) variantes puntuales (SNVs, por su acrónimo en inglés), 2) pequeñas inserciones o delecciones (INDELs), 3) cambios en número de copias (CNVs), y 4) otras variantes estructurales (SVs).

La necesidad de especialización y parametrización específica para atender cada caso de uso hace que a menudo se opte por *pipelines in-house* en lugar de soluciones comerciales. Las *pipelines in-house* se desarrollan en los propios laboratorios y son más flexibles, pero su uso plantea cuestiones normativas y de calidad, mientras que las comerciales ofrecen otras ventajas y están certificadas para algunos contextos específicos. La [tabla 1](#) resume los pros y los contras de ambos enfoques.

Los siguientes apartados describen la lógica de análisis de una *pipeline*. Los formatos de archivo generados en cada etapa, junto con las herramientas más utilizadas, se detallan en las [tablas 2-5](#), que también incluyen sus respectivas referencias.

Tabla 2 Formatos de ficheros en el proceso de análisis bioinformático

Tipo de fichero	Información que contiene	URL de documentación
fastq	lecturas de ADN (<i>reads</i>) secuenciadas y sin alinear	https://en.wikipedia.org/wiki/FASTQ_format
sam	lecturas de ADN (<i>reads</i>) secuenciadas y alineadas respecto a un genoma de referencia y en formato texto	https://samtools.github.io/hts-specs/SAMv1.pdf
bam	lecturas de ADN (<i>reads</i>) secuenciadas y alineadas respecto a un genoma de referencia y en formato binario	https://samtools.github.io/hts-specs/SAMv1.pdf
cram	lecturas de ADN (<i>reads</i>) secuenciadas y alineadas respecto a un genoma de referencia en un formato comprimido	https://samtools.github.io/hts-specs/CRAMv3.pdf
gvcf	fichero de variantes intermedio previo al paso final. Contiene todas las posiciones que potencialmente están variadas	https://sites.google.com/a/broadinstitute.org/legacy-gatk-documentation/frequently-asked-questions/4017-What-is-a-GVCF-and-how-is-it-different-from-a-regular-VCF
vcf	variantes identificadas	https://samtools.github.io/hts-specs/VCFv4.2.pdf

Listado de los distintos formatos de ficheros que se crean durante el análisis bioinformático. Se detalla su contenido y una URL donde se podrán encontrar una descripción en profundidad de las especificaciones de cada formato.

Tabla 3 Herramientas utilizadas en la primera fase de la *pipeline*

Nombre	Paso	URL
bcl2fastq	demultiplexación Illumina	https://emea.support.illumina.com/sequencing/sequencing_software/bcl2fastq-conversion-software.html
Trimmomatic	Trimming	http://www.usadellab.org/cms/?page=trimmomatic
Cutadapt	Trimming	https://cutadapt.readthedocs.io/en/stable/
BBDuk	Trimming	https://github.com/BioInfoTools/BBMap
BWA-MEM	Alineamiento	https://github.com/lh3/bwa
Bowtie2	Alineamiento	https://bowtie-bio.sourceforge.net/bowtie2/index.shtml
Minimap2	Alineamiento	https://github.com/lh3/minimap2
Picard	Suites generales	https://broadinstitute.github.io/picard/
Samtools	Suites generales	http://www.htslib.org/

La fase inicial, o «pasos comunes», consiste en a) el filtrado o *trimming*; b) el alineamiento, y c) el filtrado de duplicados. Las herramientas más comunes para realizar estas tareas se listan en la tabla junto con la URL donde se podrá encontrar el software de cada herramienta.

Tabla 4 Herramientas para la determinación de variantes

Nombre	Tipo de variante	Tipo de estudio	URL
GATK4/DeepVariant	SNVs/INDELS	panel/WES/WGS	https://gatk.broadinstitute.org/hc/en-us https://github.com/google/deepvariant
DECON	CNVs	panel/WES	https://github.com/RahmanTeam/DECoN
XHMM	CNVs	panel/WES	https://github.com/RRafiee/XHMM
panelcn.MOPS	CNVs	panel/WES	https://github.com/bioinf-jku/panelcn.mops
ExomeDepth	CNVs	panel/WES	https://github.com/vplagnol/ExomeDepth
CODEX2	CNVs	panel/WES	https://github.com/yuchaojiang/CODEX2
Genome STRiP	SVs	WGS	https://software.broadinstitute.org/software/genomestrip
Delly	SVs	WGS	https://github.com/dellytools/delly
Manta	SVs	WGS	https://github.com/Illumina/manta
LUMPY	SVs	WGS	https://github.com/arq5x/lumpy-sv
ExpansionHunter	expansiones de secuencias repetitivas	WES/WGS	https://github.com/Illumina/ExpansionHunter
GangSTR	expansiones de secuencias repetitivas	WES/WGS	https://github.com/gymreklab/GangSTR

Listado de herramientas más conocidas para la determinación de las variantes en los *reads* alineados. Las variantes que se pueden caracterizar son SNVs, INDELS, CNVs y otras SVs.

Tabla 5 Herramientas de anotación de variantes

Nombre	Tipo de variante	URL
<i>Herramientas de anotación e interpretación</i>		
Annovar	SNV/INDELS	https://annovar.openbioinformatics.org/en/latest/
snpEff	SNV/INDELS	http://pcingola.github.io/SnpEff/
VEP	SNV/INDELS	https://github.com/Ensembl/ensembl-vep
ClassifyCNV	CNV	https://github.com/Genotek/ClassifyCNV
CharGer	SVs	https://github.com/ding-lab/CharGer
AnnotSV	SVs	https://lbgj.fr/AnnotSV/
<i>Bases de datos poblacionales</i>		
GnomAD v4	SNV/INDEL/SVs	https://gnomad.broadinstitute.org/news/2023-11-gnomad-v4-0/
others	SNV/INDELS	https://www.ensembl.org/info/genome/variation/species/populations.html
<i>Predictores de patogenicidad</i>		
CADD	SNV/INDELS	sinónimas, missense, nonsense, frameshift, splicing, no codificantes, promotores y enhancers https://cadd.bihealth.org/
FATHMM	SNV/INDELS	sinónimas, missense, nonsense y frameshift http://fathmm.biocompute.org.uk/
AlphaMissense	SNVs	missense https://alphamissense.hegelab.org/
SpliceAI	SNV/INDELS	splicing https://github.com/Illumina/SpliceAI
X-CNV	CNV	— http://119.3.41.228/XCNV/index.php
CADD-SV	SV	— https://cadd-sv.bihealth.org/
<i>Bases de datos de variantes conocidas y curadas con acceso para pipelines</i>		
ClinVar	SNV/INDEL/SVs	https://www.ncbi.nlm.nih.gov/clinvar/
HGMD	SNV/INDEL/SVs	https://digitalinsights.qiagen.com/hgmd-spanish/
dbSNP	SNV/INDELS, inserciones retroposones y microsatélites	https://www.ncbi.nlm.nih.gov/snp/
ClinSV	SVs	https://github.com/KCCG/ClinSV

En la tabla se muestran las herramientas y los recursos más conocidos para realizar este paso. Primero, se listan algunos de los programas de anotación más utilizados con su URL para acceder al software. Después, se indican las bases de datos más conocidas para establecer la frecuencia alélica de las variantes. Además, se incluye un listado de predictores de patogenicidad con sus correspondientes URL. Finalmente, se indican algunas bases de datos de variantes conocidas cuyo efecto está revisado por expertos y que pueden ser accedidas por *pipelines* bioinformáticas.

Pasos comunes

El flujo de trabajo de una *pipeline* se muestra en la figura 2B. Generalmente, existe una etapa inicial que incluye: 1) procesar la salida del secuenciador; 2) filtrar, y 3) alinear las lecturas de ADN contra un genoma de referencia.

En las plataformas de secuenciación comercializadas por Illumina es necesario realizar un proceso de demultiplexado sobre la salida primaria del secuenciador. Este proceso consiste en separar los datos brutos generados por el secuenciador en diferentes muestras individuales, asignando a cada una sus correspondientes archivos *.fastq*, que contienen las lecturas de ADN (en adelante, *reads*). En caso de que la secuenciación sea *paired-end*, se obtienen lecturas desde ambos extremos de cada fragmento de ADN, lo que genera dos archivos *.fastq* por muestra.

Luego, se aplica un filtrado (*trimming*) para eliminar *reads* de baja calidad, artefactos y secuencias adaptadoras. Posteriormente, cada *read* filtrado debe alinearse con

respecto a un genoma de referencia, cuya elección influye en la caracterización de variantes¹⁵, por lo que es un aspecto importante a considerar.

Las lecturas alineadas se almacenan en archivos *.bam*, que pueden visualizarse en visores genómicos. La inspección manual de regiones de interés proporciona información valiosa a los expertos.

Cada *read* tiene un valor de calidad determinado por varios factores. Por ejemplo, en secuenciación de lectura corta las regiones genómicas poco complejas y repetitivas suelen estar cubiertas por alineamientos de baja calidad, lo que puede sesgar los conteos de cobertura y dificultar la identificación de variantes.

Determinación de variantes

Tras asignar coordenadas genómicas a cada lectura de ADN, se identifican las variantes genéticas en un proceso

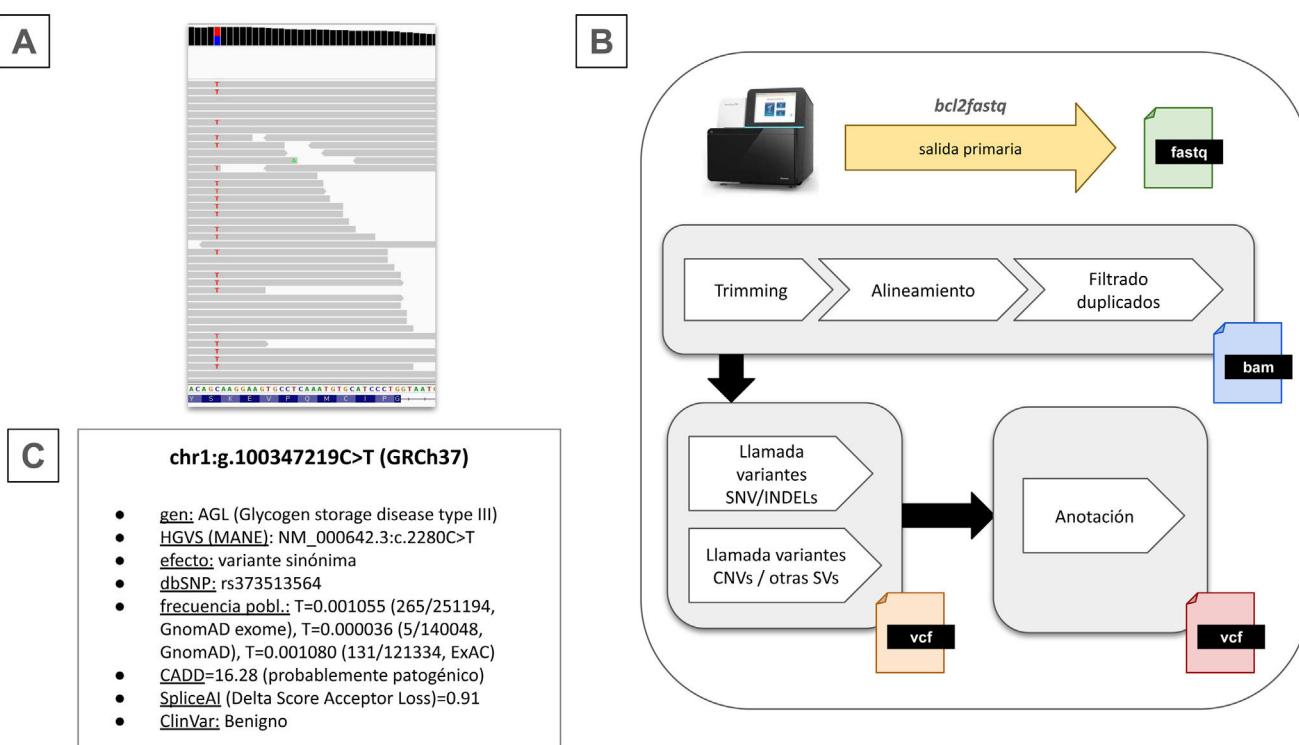


Figura 2 Resumen del análisis bioinformático.

A) Ejemplo de una variante puntual o SNV en heterocigosis en el gen AGL. Los *reads* alineados aparecen en gris, y el contenido nucleotídico del fragmento del exón mostrado se puede ver abajo en la figura. B) Etapas del proceso de análisis bioinformático que deben ejecutarse de manera secuencial mediante una *pipeline*. C) Información asociada a la variante de A) con sus *anotaciones* correspondientes que permiten la interpretación de la variante.

denominado «llamada de variantes». Este paso es altamente especializado, ya que los algoritmos empleados varían según la alteración a detectar.

Estos algoritmos se basan en métodos estadísticos y requieren una profundidad de lectura adecuada para identificar patrones. La **figura 2A** muestra una variante puntual (SNV) en el gen **AGL**.

Además de identificar la variante, es esencial determinar su cigosidad, es decir, si está en heterocigosis (un solo alelo mutado) o en homocigosis (ambos alelos mutados). Sin embargo, el proceso experimental habitualmente elimina el origen alélico de cada lectura, por lo que esta información debe inferirse posteriormente.

La información asociada a las variantes conlleva cierto grado de incertidumbre, y existe la posibilidad de que algunas sean falsos positivos. Por ello, su fiabilidad debe evaluarse a través de los *scores* de las herramientas disponibles, teniendo en cuenta los sesgos presentes en determinadas regiones genómicas. Además, se recomienda visualizar las variantes en su contexto genómico para una interpretación más precisa.

Los algoritmos para SNVs han evolucionado en la última década, y actualmente se analizan las muestras en grupos en lugar de cada una individualmente para minimizar artefactos recurrentes en lotes secuenciados conjuntamente.

GATK¹⁶ es la herramienta más conocida para este enfoque, mientras que DeepVariant¹⁷, basada en redes neuronales, se adapta a distintos contextos, incluido el

somático. Barbitoff (2022)¹⁸ ofrece una revisión general sobre herramientas bioinformáticas para SNVs e INDELs.

Para detectar cambios en el número de copias (CNVs), el método más común estima la dosis génica mediante la profundidad de lectura normalizada frente a una población control, un enfoque frecuente en estudios de captura dirigida. En WGS se combinan diversas estrategias para identificar CNVs y variantes estructurales (SVs), como grandes delecciones, duplicaciones, inversiones y translocaciones¹⁹.

Otro tipo de variante de interés, especialmente en enfermedades neurodegenerativas hereditarias, son las repeticiones en tandem y tripletes repetidos. Para conocer mejor su detección por NGS se recomienda la revisión de Genomics England²⁰.

A diferencia de SNVs/INDELs, la detección de SVs con lecturas cortas se usa principalmente con fines de cribado debido a la alta sensibilidad y la baja especificidad de los algoritmos, lo que genera una elevada tasa de falsos positivos. Esta limitación surge por restricciones tecnológicas y diseños que secuencian solo exones para maximizar la rentabilidad. En entornos clínicos, se exploran enfoques híbridos que combinan múltiples tecnologías con resultados prometedores en investigación.

Se recomienda validar las CNVs y SVs detectadas con lectura corta mediante pruebas independientes. Sin embargo, esto no siempre es posible debido a la falta de sondas comerciales para MLPA (MRC Holland) o arrays CGH/SNPs que cubran las regiones de interés. Por ello, es crucial un estudio previo para definir qué regiones incluir en los test

de NGS, excluyendo aquellas sin un método de validación claro.

Anotación

En este paso, las variantes se enriquecen con información (esto es, *anotaciones*) para su interpretación en un contexto funcional, poblacional y clínico.

Para describir SNVs e INDELS se debe utilizar la nomenclatura estándar HGVS²¹, tomando como referencia un transcríto seleccionado cuidadosamente^{22,23}. El efecto de la variante depende del transcríto elegido y podría afectar la precisión del diagnóstico.

La información funcional debe respaldarse con predicciones *in silico* mediante programas que estimen la probabilidad de que un SNV/INDEL sea deletéreo²⁴. La tabla 5 incluye un listado de los predictores más utilizados.

La información poblacional permite determinar la presencia de variantes en la población de referencia. La base de datos gnomAD²⁵ es uno de los recursos más completos, ya que contiene datos de 195.000 individuos considerados población control.

También debe integrarse información de variantes conocidas y revisadas por expertos, como la que aporta dbSNP, ClinVar y HGMD (esta última requiere licencia).

Aunque el flujo de trabajo para SNVs e INDELS está estandarizado, las herramientas para la anotación de CNVs y SVs son aún limitadas y carecen de estándares ampliamente aceptados. Es recomendable considerar herramientas como ClassifyCNV y AnnotSV, así como CharGer, que incorpora los criterios del American College of Medical Genetics and Genomics (ACMG)²⁶, reconocidos como referencia para la clasificación de variantes.

Filtrado y priorización e interpretación

La falta de una definición clara de las funciones de los bioinformáticos clínicos genera diferentes perspectivas sobre quién debería encargarse del filtrado y de la priorización de variantes.

Es recomendable que este paso sea realizado por expertos moleculares, quienes deben determinar la patogenicidad de las variantes candidatas siguiendo el sistema de clasificación ACMG.

Sin embargo, en estudios genéticos complejos se requiere de la panelización virtual y/o filtros avanzados mediante algoritmos específicos. Por tanto, es fundamental que los bioinformáticos colaboren estrechamente con los genetistas moleculares para apoyar la toma de decisiones en la fase final del test de NGS.

Existen diversas herramientas de filtrado y priorización que facilitan estas tareas; la mayoría requieren licencia, permitiendo manejar amplias listas de variantes, aunque su descripción queda fuera del alcance de esta revisión.

Otras consideraciones

Las metodologías de análisis evolucionan constantemente, por lo que es fundamental actualizar las pipelines con algoritmos más eficaces y bases de datos actualizadas. Dado que

no existe una normativa que regule la frecuencia de estas actualizaciones, es crucial documentar detalladamente las versiones de las *pipelines*, el software utilizado y los recursos empleados, asegurando que esta información se recoja en los informes moleculares para trazar el proceso analítico.

Las *pipelines* necesitan ser monitorizadas para conocer su rendimiento a lo largo del tiempo y asegurar su validez ante cambios introducidos en el proceso diagnóstico. También, en *pipelines in-house*, en la fase de desarrollo previo es fundamental ajustar correctamente los parámetros de los programas.

Por ello, es necesario utilizar muestras de referencia bien caracterizadas, como las del consorcio *Genome in a Bottle* (GIAB)²⁷, con el fin de optimizar el rendimiento y evaluar la reproducibilidad de los resultados. Sin embargo, no están disponibles materiales de referencia para ciertas alteraciones, lo que laстра la implantación de algoritmos bien calibrados en la rutina diagnóstica.

En el caso de la muestra NA12878/HG001 de GIAB, se pueden adquirir viales con ADN de este individuo, lo que permite validar tanto el proceso bioinformático de forma independiente como el flujo completo, desde las primeras etapas experimentales.

Existen, además, evaluaciones periódicas para establecer un rendimiento estándar de referencia, como los esquemas de evaluación de EMQN. Es altamente recomendable seguir alguna evaluación externa que permita evaluar la competencia de las *pipelines*.

La reproducibilidad de los resultados obtenidos con las *pipelines* puede verse afectada por la infraestructura hardware y las versiones de las herramientas empleadas. Por este motivo, se aconseja ejecutar las *pipelines* en contenedores²⁸, ya que estos encapsulan el código con todas las dependencias y archivos necesarios, garantizando la consistencia en cualquier entorno y mejorando la portabilidad, la traza y la reproducibilidad.

Esquema de análisis de calidad

La *pipeline* de análisis debe complementarse con procesos de revisión de calidad. Su objetivo principal es determinar qué muestras son aptas para el diagnóstico y, en los casos negativos, objetivar el motivo, ya sea por incidencia u otras razones. Además, proporcionar información sobre la efectividad del proceso experimental.

Es importante señalar que los marcadores de calidad no están estandarizados y, hasta el momento, no existe un consenso sobre cuáles deberían ser analizados e incluidos en los informes de forma obligatoria. La descripción detallada de los marcadores más comúnmente utilizados excede el alcance de este artículo, ya que requiere un tratamiento más amplio y exhaustivo. No obstante, la tabla 6 presenta una selección de aspectos de calidad que deben considerarse tanto para la supervisión del proceso como para la revisión de las muestras.

Limitaciones de la secuenciación de lectura corta

La secuenciación de lectura corta presenta limitaciones debido al tamaño reducido de los fragmentos, lo que resulta

Tabla 6 Aspectos de calidad para supervisar el test de NGS y analizar la idoneidad de las muestras

Aspecto de calidad	Análisis bioinformático	Análisis molecular
Establecer la sensibilidad y la especificidad del proceso de análisis	Sí, con muestras de referencia. Esta información deberá incluirse en el informe molecular	Sí, con la participación en esquemas de validación oficiales (EMQN). Esta información deberá incluirse en el informe molecular
Establecer la reproducibilidad de las métricas de rendimiento	Sí, con monitorización periódica y comparativas inter-laboratorio	Sí, con análisis de doble ciego de la misma muestra y comparativas inter-laboratorio
Establecer la replicabilidad de las métricas de rendimiento	Sí, usando diferentes muestras de referencia	Sí, con análisis de doble ciego y comparativas inter-laboratorio de manera periódica con muestras diferentes y de paneles diversos
Establecer la reproducibilidad y la trazabilidad del proceso de análisis para una muestra dada	Sí, con <i>pipelines</i> en contenedores y un esquema de datos que permita guardar la información técnica completa. Esta información deberá incluirse en el informe molecular –	Sí, con un protocolo de priorización consensuado y documentado. Protocolo de copias de seguridad de los pasos protocolizados que permitan trazar la toma de decisiones
Establecer la validez clínica y la utilidad diagnóstica		Sí, con la participación en esquemas de validación oficiales (EMQN)
Implantar marcadores de calidad en cada una de las muestras	Sí. Los marcadores deberán estar documentados. Los límites de normalidad deberán establecerse con estudios estadísticos robustos. Cada muestra deberá estar etiquetada como «apta para el diagnóstico», «no apta», «apta con incidencias»	Los genetistas moleculares deberán conocer los marcadores de cada muestra y deberán tener formación para comprenderlos. Ante una reclamación de una muestra «no apta», deberán poder objetivar los motivos de retraso al médico peticionario. Se deben confirmar las alteraciones o, en su defecto, establecer una metodología que minimice los FP
Unificar criterios y formato de informe molecular	Sí. La Unidad de Bioinformática deberá participar en la definición y formato de la información relevante a incluir en el informe	Sí, los genetistas moleculares deberán establecer criterios comunes, protocolos de análisis y herramientas que faciliten el trabajo. Deberá haber un criterio común de reporte de los hallazgos incidentales. El informe molecular deberá estar unificado y todos los casos de uso incluidos
Establecer marcos de calidad estándar conforme a alguna norma de calidad o ISO y alcanzar certificación	Sí. La Unidad de Bioinformática deberá participar de la norma de calidad. Si el modelo es «híbrido» o «externalizado», también se deberán adecuar los procesos de calidad para cumplir la norma ISO	Sí. Los genetistas moleculares deberán participar de la norma de calidad. Si el modelo es «híbrido» o «externalizado», también se deberán adecuar los procesos de calidad para cumplir la norma ISO
Acreditar el laboratorio con una norma UNE-EN	Sí. La Unidad de Bioinformática deberá cumplir con la norma que acredita la competencia del proceso de análisis, esté externalizado o no	Sí. Los genetistas moleculares deberán cumplir con la norma que acredita la competencia del proceso de análisis, esté externalizado o no

Listado de aspectos a tener en cuenta en un proceso de calidad tanto en la etapa de análisis bioinformático como la posterior interpretación de variantes en la fase de análisis molecular y redacción de informe al paciente.

en alineamientos ambiguos en ciertas regiones. En especial, fragmentos de baja complejidad (homopolímeros), regiones repetitivas (repeticiones en tandem) o con alta homología (duplicaciones segmentales y pseudogenes). Esto dificulta determinar con precisión la localización de los *reads*, especialmente cuando las regiones repetidas superan el tamaño del fragmento.

Los algoritmos de alineamiento asignan múltiples localizaciones genómicas a cada *read*, reduciendo la calidad y sesgando la identificación de variantes, produciendo

variantes artefactuales o una falta en su identificación. Un ejemplo es el gen *PKD1*, crucial para el diagnóstico de poliquistosis renal, donde la presencia de pseudogenes reduce drásticamente las variantes identificadas, requiriendo métodos más avanzados²⁹.

Nuevos protocolos, como *linked reads* y tecnologías de lectura larga, están demostrando su efectividad en la resolución de ciertas regiones que suponen un reto tecnológico, como las que codifican los antígenos leucocitarios humanos (HLA)³⁰.

Romper la barrera diagnóstica implica explorar nuevas aproximaciones e incorporar otras tecnologías ómicas, tal y como se ha expuesto en apartados anteriores.

Explotación de datos de NGS

Los datos genómicos deben tratarse como datos médicos y, por tanto, deben ser gestionados por los mismos responsables que custodian la historia clínica en los sistemas de salud.

El reanálisis por ajustes en la sospecha diagnóstica, nuevos familiares afectados o la explotación del historial de variantes exige que los datos sigan accesibles. Por ello, los sistemas de archivado deben garantizar su consulta durante el período legal y más allá de este.

Estructurar el histórico de pacientes facilita la interpretación de variantes candidatas, ya que su presencia/ausencia en la cohorte permite establecer sus clasificaciones con más confianza. Las consultas y la interconexión entre diferentes bases de datos pueden realizarse mediante el protocolo *Beacon*³¹ y permiten incorporar información clínica del paciente.

La explotación secundaria es fundamental para alimentar el ciclo de investigación-desarrollo-implementación para que los laboratorios ajusten sus prácticas a los avances tecnológicos, siempre y cuando los consentimientos informados permitan la reutilización de la información.

Finalmente, es importante anonimizar los archivos de NGS para cumplir con el Reglamento general de protección de datos (RGPD), evitando incluir información personal de los pacientes.

Aspectos normativos

Desde 2014, Eurogentest ha emitido recomendaciones para mejorar la precisión de los test genéticos, como la guía publicada para el análisis de WGS³². En Europa, NEQAS (Reino Unido) y VKGL (Países Bajos) son referencia de buenas prácticas en NGS, ante la ausencia de un marco regulatorio. Sin embargo, la acreditación ISO 15189 está muy extendida en los laboratorios de NGS dentro del ámbito europeo.

Las *pipelines in-house* son consideradas productos sanitarios para diagnóstico *in vitro* y están reguladas por el Reglamento (UE) 2017/746. A nivel nacional, se está actualizando la normativa que reemplazará al Real Decreto 1662/2000, y un grupo de trabajo europeo ha elaborado una guía al respecto³³.

Si se eligen servicios de un tercero para custodiar datos en la nube, este debe demostrar que cumple con sus obligaciones respecto a la gestión de datos personales y de salud según el RGPD³⁴.

Discusión

El análisis bioinformático en pruebas de NGS es complejo y demanda personal especializado, una infraestructura adecuada y capacitación del personal facultativo para interpretar correctamente los resultados.

Es esencial la supervisión y el control de calidad para garantizar la validez analítica y clínica del test. Esto es

especialmente relevante en casos en que se delega el análisis bioinformático a un tercero.

Aunque la tecnología de lectura corta ha mostrado gran eficiencia y una elevada tasa diagnóstica, es necesario integrar nuevas tecnologías para abordar los casos sin diagnóstico y romper el techo diagnóstico en aquellos donde las bases genéticas no son conocidas o la manifestación clínica es compleja.

Los aspectos normativos son clave, pero aún falta avanzar hacia prácticas estandarizadas y consensuadas por la comunidad de expertos. En este sentido, las administraciones deben asumir un papel más activo para promover la estandarización y las buenas prácticas en el área.

Declaración sobre el uso de inteligencia artificial

Durante la preparación de este trabajo, la autora ha utilizado ChatGPT con el fin de mejorar la legibilidad del texto escrito por ella. Tras utilizar esta herramienta/servicio, la autora ha revisado y editado el contenido según fue necesario y asume plena responsabilidad por el contenido de la publicación.

Conflictos de intereses

La autora declara que no existen conflictos de intereses relacionados con esta publicación.

Bibliografía

- Heather JM, Chain B. The sequence of sequencers: The history of sequencing DNA. *Genomics*. 2016;107:1–8.
- Metzker ML. Sequencing technologies — the next generation. *Nat Rev Genet*. 2010;11:31.
- Amarasinghe SL, Su S, Dong X, Zappia L, Ritchie ME, Gouil Q. Opportunities and challenges in long-read sequencing data analysis. *Genome Biol*. 2020;21:1–16.
- Fairley S, Lowy-Gallego E, Perry E, Flicek P. The International Genome Sample Resource (IGSR) collection of open human genomic variation resources. *Nucleic Acids Res*. 2020;48:D941–7.
- Taliun D, Harris DN, Kessler MD, Carlson J, Szpiech ZA, Torres R, et al. Sequencing of 53,831 diverse genomes from the NHLBI TOPMed Program. *Nature*. 2021;590:290.
- PHG Foundation Guidelines for targeted next generation sequencing. 2014;1–5.
- Roy S, Coldren C, Karunamurthy A, Kip NS, Klee EW, Lincoln SE, et al. Standards and guidelines for validating next-generation sequencing bioinformatics pipelines: A joint recommendation of the Association for Molecular Pathology and the College of American Pathologists. *J Mol Diagn*. 2018;20:4–27.
- Burke W. Genetic tests: Clinical validity and clinical utility. *Curr Protoc Hum Genet*. 2014;81:9.15.1–8.
- Illumina Inc. NovaSeq 6000. Disponible en: https://support.illumina.com/content/dam/illumina-support/documents/documentation/system_documentation/translations/novaseq-site-prep-guide-1000000019360-esp.pdf
- Gillette MA, Jimenez CR, Carr SA. Clinical proteomics: A promise becoming reality. *Mol Cell Proteomics*. 2024;23:100688.
- Dalamaga M. Clinical metabolomics: Useful insights, perspectives and challenges. *Metabol Open*. 2024;22:100290.

A. del Pozo

12. Isla D, Lozano MD, Paz-Ares L, Salas C, de Castro J, Conde E, et al. Nueva actualización de las recomendaciones para la determinación de biomarcadores predictivos en el carcinoma de pulmón no célula pequeña: Consenso Nacional de la Sociedad Española de Anatomía Patológica y de la Sociedad Española de Oncología Médica. *Rev Esp Patol.* 2023;56:97–112.
13. Stenton SL, Prokisch H. The clinical application of RNA sequencing in genetic diagnosis of Mendelian disorders. *Clin Lab Med.* 2020;40:121–33.
14. Kerkhof J, Rastin C, Levy MA, Relator R, McConkey H, Demain L, et al. Diagnostic utility and reporting recommendations for clinical DNA methylation episignature testing in genetically undiagnosed rare diseases. *Genet Med.* 2024;26:101075.
15. Li H, Dawood M, Khayat MM, Farek JR, Jhangiani SN, Khan ZM, et al. Exome variant discrepancies due to reference-genome differences. *Am J Hum Genet.* 2021;108:1239–50.
16. Depristo MA, Banks E, Poplin R, Garimella KV, Maguire JR, Hartl C, et al. A framework for variation discovery and genotyping using next-generation DNA sequencing data. *Nat Genet.* 2011;43:491.
17. Poplin R, Chang P, Alexander D, Schwartz S, Colthurst T, Ku A, et al. A universal SNP and small-indel variant caller using deep neural networks. *Nat Biotechnol.* 2018;36:983–7.
18. Barbitoff YA, Abasov R, Tvorogova VE, Glotov AS, Predeus AV. Systematic benchmark of state-of-the-art variant calling pipelines identifies major factors affecting accuracy of coding sequence variant discovery. *BMC Genomics.* 2022;23:155–63.
19. Chaisson MJP, Sanders AD, Zhao X, Malhotra A, Porubsky D, Rausch T, et al. Multi-platform discovery of haplotype-resolved structural variation in human genomes. *Nat Commun.* 2019;10:1–16.
20. Ibanez K, Polke J, Hagelstrom RT, Dolzhenko E, Pasko D, Thomas ERA, et al., Genomics England Research Consortium. Whole genome sequencing for the diagnosis of neurological repeat expansion disorders in the UK: A retrospective diagnostic accuracy and prospective clinical validation study. *Lancet Neurol.* 2022;21:234–45.
21. HVNC HGVS. <https://hgvs-nomenclature.org>
22. McCarthy DJ, Humburg P, Kanapin A, Rivas MA, Gaulton K, Cazier J, et al. Choice of transcripts and software has a large effect on variant annotation. *Genome Med.* 2014;6:26.
23. Schoch K, Tan QK, Stong N, Deak KL, McConkie-Rosell A, McDonald MT, et al. Alternative transcripts in variant interpretation: The potential for missed diagnoses and misdiagnoses. *Genet Med.* 2020;22:1269–75.
24. Katsonis P, Wilhelm K, Williams A, Lichtarge O. Genome interpretation using *in silico* predictors of variant impact. *Hum Genet.* 2022;141:1549–77.
25. gnomAD v4 database. <https://gnomad.broadinstitute.org/news/2023-11-gnomad-v4-0/>
26. Walker LC, Hoya MDL, Wiggins GAR, Lindy A, Vincent LM, Parsons MT, et al. Using the ACMG/AMP framework to capture evidence related to predicted and observed impact on splicing: Recommendations from the ClinGen SVI Splicing Subgroup. *Am J Hum Genet.* 2023;110:1046.
27. Zook JM, Hansen NF, Olson ND, Chapman L, Mullikin JC, Xiao C, et al. A robust benchmark for detection of germline large deletions and insertions. *Nat Biotechnol.* 2020;38:1347.
28. Kadri S, Sboner A, Sigaras A, Roy S. Containers in bioinformatics: Applications, practical considerations, and best practices in molecular pathology. *J Mol Diagn.* 2022;24:442–54.
29. Ali H, al-Mulla F, Hussain N, Naim M, Asbeutah AM, AlSahow A, et al. PKD1 Duplicated regions limit clinical Utility of Whole Exome Sequencing for Genetic Diagnosis of Autosomal Dominant Polycystic Kidney Disease. *Sci Rep.* 2019;9:4141.
30. Matern BM, Olieslagers TI, Groeneweg M, Duygu B, Wieten L, Tilanus MGJ, et al. Long-read nanopore sequencing validated for human leukocyte antigen class I typing in routine diagnostics. *J Mol Diagn.* 2020;22:912–9.
31. Rambla J, Baudis M, Ariosa R, Beck T, Fromont LA, Navarro A, et al. Beacon v2 and Beacon networks: A "lingua franca" for federated data discovery in biomedical genomics, and beyond. *Hum Mutat.* 2022;43:791–9.
32. Eurogentest Eurogentest guidelines 2014. <https://www.phgfoundation.org/wp-content/uploads/2023/11/Eurogentest-guidelines.pdf> (accessed Eurogentest guidelines, 2014).
33. MDCG MDCG recommendations. https://health.ec.europa.eu/system/files/2023-01/mdcg_2023-1-en.pdf
34. AEPD RGPD. <https://www.aepd.es/guias/guia-profesionales-sector-sanitario.pdf>