


Analisi bioinformatica nell'era NGS: biotools a supporto della tipizzazione HLA.

Veronica Scaglia



UO Biologia dei Trapianti, Diagnostica Molecolare e Manipolazione CSE

Dipartimento di Patologia Clinica, AUSL Piacenza




SERVIZIO SANITARIO REGIONALE
EMILIA ROMAGNA
Azienda Unità Sanitaria Locale di Piacenza

Sequenziamento NGS piattaforma Illumina



1 lane contiene 2 file di tiles



I tiles contengono
poi i clusters

Analisi dei dati NGS: *workflow*

Analisi primaria

Racchiude tutti gli step utili a determinare la sequenza delle basi, è tipicamente eseguita dal sequenziatore dopo ogni ciclo.

Produce letture (*reads*) in formato FastQ



Analisi secondaria

Racchiude tutti i processi necessari ad allineare i frammenti sequenziati (*contig*), escludendo i dati di bassa qualità.



Analisi terziaria

Visualizzazione dei dati prodotti grazie a software dedicati

Interpretazione dei dati



A. RTA Logs folder— Contains log files that describe each step performed by RTA for each Read.

B. InterOp folder— Contains binary files used by Sequencing Analysis Viewer (SAV) to summarize various primary analysis metrics.

C. Logs folder— Contains log files that describe every step performed by the instrument for each cycle.


D. RunInfo.xml— Contains high-level run information, such as the number of Reads and cycles in the sequencing run.

E. runParameters.xml— Contains a summary of run parameters and information about run components.

F. SampleSheet.csv— Provides parameters for the run and subsequent analysis.

G. Alignment folder— Contains alignment (*.bam) and variant call (*.vcf) files. This folder is not created if you set up your run with the GenerateFASTQ workflow.

H. FASTQ files— Provide intermediate analysis data for downstream third-party analysis. Files are located in Data\Intensities\BaseCalls.



Sequencing Analysis Viewer

Analysis Tab


- **Flow Cell Chart** mostra i parametri di qualità delle sezioni sulla flowcell in codice colore
- **Data by Cicle** mostra un grafico che permette di seguire la progressione dei parametri di qualità durante tutta la corsa
- **Data by Lane** mostra i parametri di qualità per ogni lane
- **Q Score Distribution Plot** mostra in un grafico il numero di reads che superano il filtro di qualità
- **Q score Heatmap** mostra il Q score per ogni ciclo di sequenziamento.



Sequencing Analysis Viewer

Imaging Tab

- Mostra una lista dettagliata dei parametri e dei dati della corsa.
- Ogni lane, ciclo, sezione può essere selezionata per valutarne le caratteristiche specifiche.



Sequencing Analysis Viewer

Summary Tab

- Mostra i dati di qualità grezzi in una tabella riassunti per lane e per read. Le statistiche mostrano medie e deviazioni standard delle varie lane.
- Cluster Density: 600-1200 K/mm²
- Cluster Passing Filter: >80%
- % reads \geq Q30: >90%

Sequencing Analysis Viewer

Run Folder: D:\Illumina\MiSeqAnalysis\160816_M70109_0001_000000000-AJTY0

Analysis	Imaging	Summary	Indexing
Read 3 (I)	0.13	0.13	0.00 0.00 60 97.44
Read 4	2.25	2.25	1.43 0.53 117 94.14
Non-Indexed Total	4.50	4.50	1.47 0.40 126 95.45
Total	4.76	4.76	1.47 0.40 232 95.48

Read 1

Lane	Tiles	Density (K/mm2)	Cluster PF (%)	Phas/Prephas (%)	Reads (M)	Reads PF (M)	% \geq Q30	Yield (G)	Cycles Err Rated	Aligned (%)	Error Rate (%)	Error Rate 35 cycle (%)	Error Rate 75 cycle (%)
1	28	1078 +/- 21	91.22 +/- 1.29	0.070 / 0.134	20.54	18.74	96.77	2.25	120	1.51 +/- 0.04	0.27 +/- 0.03	0.13 +/- 0.01	0.17 +/- 0.02

Read 2 (I)

Lane	Tiles	Density (K/mm2)	Cluster PF (%)	Phas/Prephas (%)	Reads (M)	Reads PF (M)	% \geq Q30	Yield (G)	Cycles Err Rated	Aligned (%)	Error Rate (%)	Error Rate 35 cycle (%)	Error Rate 75 cycle (%)
1	28	1078 +/- 21	91.22 +/- 1.29	0.000 / 0.000	20.54	18.74	94.61	0.13	0	0.00 +/- 0.00	0.00 +/- 0.00	0.00 +/- 0.00	0.00 +/- 0.00

Read 3 (I)

Lane	Tiles	Density (K/mm2)	Cluster PF (%)	Phas/Prephas (%)	Reads (M)	Reads PF (M)	% \geq Q30	Yield (G)	Cycles Err Rated	Aligned (%)	Error Rate (%)	Error Rate 35 cycle (%)	Error Rate 75 cycle (%)
1	28	1078 +/- 21	91.22 +/- 1.29	0.000 / 0.000	20.54	18.74	97.44	0.13	0	0.00 +/- 0.00	0.00 +/- 0.00	0.00 +/- 0.00	0.00 +/- 0.00

Read 4

Lane	Tiles	Density (K/mm2)	Cluster PF (%)	Phas/Prephas (%)	Reads (M)	Reads PF (M)	% \geq Q30	Yield (G)	Cycles Err Rated	Aligned (%)	Error Rate (%)	Error Rate 35 cycle (%)	Error Rate 75 cycle (%)
1	28	1078 +/- 21	91.22 +/- 1.29	0.076 / 0.081	20.54	18.74	94.14	2.25	120	1.43 +/- 0.03	0.53 +/- 0.08	0.37 +/- 0.23	0.44 +/- 0.11

Il file FASTQ

Nome Strumento ID corsa ID flowcell *lane* flowcell numero del *tile*
Coordinate del *cluster* Paired-end N read ha passato il filtro, altrimenti Y
indice

```
1 @M06634:435:000000000-GLH9R:1:1101:19310:1923:2:N:0:11
2 CTCAGAAATGTGAGGAGCCTTGCTAGCGGCTCTCCATAGACTTTCCAGTGGAGGAAATAGTGC
3 +
4 1>11111111B331111AAFGG10A111000ABGFHBA1D211ADGHH21212A01A//00B11221
```

1. Si riferisce all'identificativo della sequenza (inizia con @)
2. La seconda riga mostra la sequenza grezza
3. Contiene il simbolo "+" seguito da spazio
4. Contiene i parametri di qualità della sequenza codificati come conversione decimale del codice ASCII (American Standard Code for Information Interchange)

I file *.SAM e *.BAM

- Il SAM (Sequence Alignment Map) è un formato di archiviazione di file di allineamento con le relative coordinate di interpretazione.
- Viene utilizzato in diversi *workflow* di sequenziamento per allineare le reads ad una sequenza di riferimento.
- BAM è un file SAM compresso, scritto in codice binario. Non decifrabile da un operatore, ma solo da software dedicati.
- Alcuni tools permettono di convertire i file *.SAM in *.BAM (es. Samtools)

Controllo qualità dei FASTQ nella tipizzazione HLA

- Permette di affiancare i software commerciali per migliorare la qualità del dato;
- Permette di identificare eventuali problemi sorti durante il sequenziamento;
- Utile in fase di validazione / monitoraggio continuo per identificare le caratteristiche intrinseche della metodica;
- Identificazione e miglioramento dell'eventuale errore introdotto durante le fasi della metodica.

FastQC

- Tool gratuito di controllo qualità dei dati NGS
- File input *.fastq, *.bam, *.sam
- Generazione di un report *.html con i parametri di qualità del file inserito (visualizzabile tramite browser)
- In caso di sequenziamenti *paired-end* vanno inseriti entrambi i files *.fastq generati e verranno analizzati separatamente.



Andrews, S. (2010). FastQC: A Quality Control Tool for High Throughput Sequence Data

- 📁 Configuration
- 📁 Help
- 📁 net
- 📁 org
- 📁 Templates
- 📁 uk
- 📄 cisd-jhdf5.jar
- 📄 fastqc
- ❓ fastqc_icon.ico
- 📄 htsjdk.jar
- 📄 INSTALL.txt
- 📄 jbzip2-0.9.jar
- 📄 LICENSE
- 📄 LICENSE.txt
- 📄 LICENSE_JHDF5.txt
- 📄 README.md
- 📄 README.txt
- 📄 RELEASE_NOTES.txt
- ⚙️ run_fastqc.bat

- 📄 adapter_list.txt
- 📄 contaminant_list.txt
- 📄 limits.txt

- 📁 1 Introduction
- 📁 2 Basic Operations
- 📁 3 Analysis Modules

N.B. Questi file *.txt
possono essere modificati
manualmente
dall'operatore per adattarli
alle esigenze specifiche di
analisi.



FastQC Report


Summary

-  [Basic Statistics](#)
-  [Per base sequence quality](#)
-  [Per tile sequence quality](#)
-  [Per sequence quality scores](#)
-  [Per base sequence content](#)
-  [Per sequence GC content](#)
-  [Per base N content](#)
-  [Sequence Length Distribution](#)
-  [Sequence Duplication Levels](#)
-  [Overrepresented sequences](#)
-  [Adapter Content](#)
-  [Kmer Content](#)


Basic Statistics

Measure	Value
Filename	HA-241163-514-706_S8_L001_R1_001.fastq.gz
File type	Conventional base calls
Encoding	Sanger / Illumina 1.9
Total Sequences	313531
Total Bases	46.6 Mbp
Sequences flagged as poor quality	0
Sequence length	35-151
%GC	50

Per base sequence quality




✓ Per base sequence quality




- Il box giallo rappresenta la qualità del 25-75% delle reads in quella posizione, i whiskers sotto il box giallo rappresentano il limite del 10% e 90%. Tendenzialmente la qualità tende ad abbassarsi per corse molto lunghe.

✗ Per tile sequence quality




- Nelle librerie di Illumina sono presenti informazioni relative all'identificativo della sequenza, per cui è possibile ricostruire la qualità associata ai *tile* per identificare eventuali problemi in una regione della flowcell. Le sfumature di blu indicano buona qualità.

✓ **Per sequence quality scores**




- Parametri di qualità medi per read, valori sotto 20 indicano probabilità di errore dell' 1% nell'assegnazione delle basi, il valore ottimale è sopra 27.

✓ **Per base N content**




- Il valore N viene assegnato in una posizione quando il sequenziamento non è in grado di assegnare la base. Questo grafico mostra la % di basi chiamate in ogni posizione, per le quali è stata assegnata una N. Un aumento di %N può indicare che un bias della reazione rende il *basecaller* instabile.

✖ Per base sequence content




✖ Kmer Content



- Questo parametro mostra la proporzione della presenza di ogni base nel sequenziamento. In una libreria ottimale le proporzioni dovrebbero mantenersi costanti. All'inizio della sequenza si può verificare sbilanciamento per bias nella frammentazione o *random priming*; in questo caso non interferisce con la qualità del dato a valle.


- Il Kmer content parte dal presupposto che piccoli segmenti di sequenza (*Kmeri*) dovrebbero essere equamente rappresentati all'interno di una *library*. All'inizio della sequenza questo dato può aumentare in caso di *random priming*, ed è correlato al "Per base sequence content".

✓ Per sequence GC content




- Questa sezione mostra il *GC content* sull'intera distribuzione delle sequenze, viene comparata ad una distribuzione normale teorica del *GC content*. La curva relativa al sequenziamento deve essere il più possibile sovrapponibile alla distribuzione normale.

✗ Per sequence GC content




- Uno *shift* nella curva osservata indica un bias nella rappresentazione delle basi, che può essere dato da contaminazione o da problemi della *library*. Uno *shift* sistematico non viene indicato come errore, siccome può essere una caratteristica intrinseca della *library*.

⚠ Sequence Length Distribution




- Le sequenze dovrebbero avere tutte la stessa lunghezza, che dipende dalla metodica utilizzata.

✓ Adapter Content



- Questo grafico mostra l'eventuale sovrarappresentazione di adapter nel sequenziamento. Nel software è presente una lista di adapter di default che può essere modificata manualmente dall'operatore nella sezione Configuration > adapter_list.txt

✖ Sequence Duplication Levels



-In una *library* tendenzialmente le sequenze sono diversificate; quando alcune sequenze sono presenti in doppio ciò può indicare over-amplificazione nella PCR, contaminati a bassa complessità, sequenze sovra rappresentate.

✖ Overrepresented sequences

Sequence	Count	Percentage
GATCGGAAGAGCACACGTCTGAACCTCCAGTCACGACATAGTATCTGTAT	7459	2.67885361298664
NN	2629	0.9441890532969401
GGCAGACAGTGTGACAAAGAGGGCTGGTGTAGGAGAAGAGGGATCAGGACG	677	0.24314035339750034
TGGATACTCACGACGCCAGTTCTCACTCCCATTGGGTGTCGGGTT	580	0.20830340468323516
CTCATCTTCTGCCTCTCCATTCTCTGCTATAGTTCAAGTCCCTCTA	426	0.15299525930182445
CTCATCTTCTGCCTCTCCATTCTCTGCTATAGTTCAAGTCCCTCTA	406	0.14581238327826462
GCAGGTGCCTTGAGAAACAAAGTCAGGGTTCTCAAGTCACAAAGGA	400	0.14365752047119665
CTGGGGAGGAAACACAGGTCAGCATGGAACAGGGTCACAGTGGACACG	294	0.10558827754632956

-Nella maggioranza dei sequenziamenti HLA da noi analizzati, sono presenti sequenze over rappresentate. Il software riporta la percentuale delle sequenze più abbondanti sopra lo 0,1% del totale. Nel software è presente una lista di contaminati di default identificabili, che può essere modificata manualmente dall'operatore nella cartella Configuration > contaminat_list.txt


✖ Overrepresented sequences

Sequence	Count	Percentage	Possible Source
GATCGGAAGAGCACACGTCTGAACCTCCAGTCACGTCTATGAATCTGTAT	5189	1.2673902848880378	TruSeq Adapter, Index 11 (97% over 38bp)
NN	1483	0.36221618664269806	No Hit
CTCATCTTCTGCCTCTCCATTCCCTTGCTTGCTATAGTTCACTAGCCCTCTA	1148	0.28039391926218293	No Hit
CTCATCTTCTGCCTCTCCATTCCCTTACTTTCTATACATCAGCCCTCTA	466	0.11381843760991052	No Hit

- Nel sequenziamento HLA la sequenza più abbondante (sopra l'1%) fa spesso riferimento agli indici di Illumina
- Sono presenti altre sequenze di origine ignota che si è reso necessario indagare



Ricerca delle sequenze nel database
NCBI BLAST



FastQC

File Help

225033 ICL A

Overrepresented sequences				
	Sequence	Count	Percentage	Possible Sou..
GATCGGAAGAGCACACGTCTGAACCTCCAGTCACGTCTATGAATCTCGTAT	5189	1,267	TruSeq Adapt.	
NN	1483	0,362	No Hit	
CTCATCTTCTGCCTCTCCATTTCCTGCTTGCTATAGTTCAGTCCCTCTA	1148	0,28	No Hit	
CTCATCTTCTGCCTCTCCATTTCCTTACTTCTATACATCAGCCCCCTCTA	466	0,114	No Hit	

Homo sapiens, HLA-DRB1 gene for MHC class II antigen, cell line DKMS-LSL ID15821130 DRB1_1, allele HLA-DRB1*14:new

Caltrans LRSR2072

OneBook TA



FastQC

File Help


UCLAHLA1114ANNO2024-241036-513-702 S8 L001 R1 001.fastq.gz UCI AHLA1114ANNO2024-241036-513-702 S8 L001 R2 001.fastq.gz

- Per sequence GC content
- Per base N content
- Sequence Length Distribution
- Sequence Duplication Levels
- Overrepresented sequences

Homo sapiens HLA-B gene for MHC class I antigen, allele HLA-B*13:02:01:new

Digitized by srujanika@gmail.com

◎ 一月一號 一九八九年



HLAB5'UTR	GGCAGACAGTGTGACAAAGAGGCTGGTAGGAGAAGAGGGATCAGGACG
HLAA5'UTR	TGGATACTCACGACGCCAGTCTCACTCCCATTGGGTGTCGGGTT
HLADRB1INTRON1	CTCATCTTCTGCCTCTCCATTTCCTGCTTGTATAGTTCAAGTCCCTCTA
HLADRB1INTRON1	CGCCTCAGGAAGACAGAGGAGGCCCTGGGCTGCAGGGGGTGGCGTT
HLAA3'UTR	GCAGGTGCCTTGCAGAACAAAGTCAGGGTTCTTCAAGTCACAAAGGGA
HLAB3'UTR	CTGGGGAGGAAACACAGGTCAAGCATGGAACAGGGGTACAGTGGACACG
HLADQB15'UTR	GCCAGGTACATCAGATCCATCAGGTCCGAGCTGTGTTGACTACCAACT
HLADQB15'UTR	CGCAGGCTGTTCCACAGCTCCGGCGGGCTCAGGGCGGGCTGCAGGGGT
HLADQB13'UTR	GCGTGACAGCCACTGTAGGACTTTGATCTCAGGGGACAAGCTGACACAG
HLADRB15'UTR	TGTCAAGTGGGAAATGAATGCTCTTACAAGGCTCAAACATTGTGAAACACAT
HLADPB13'UTR	GGGGTTCATGCCTGAGATCCCTCTGGAGGAGCCTCAGTGTACAAATG
HLADPB13'UTR	GGCCTGGAGAGGCTCTGCACCCGCTTAGGACCACAGAACTCGGTACTAG
HLADPA13'UTR	GTCCAAGTAGAGACAGTAAGTAGTTACAGGCACCCACACTGTGTTGT
HLADQA15'UTR	AGACATGCACACACCAGAGAAGATTCCGATTTCGTGTCCTCCCTCTATTG
HLADRB53'UTR	GAACCGGTAGCAACCAGGGCTGAGAAAGTCCTCTTGTGGAAGAATAA
HLADRB5INTRON1	CGGATCCTCCTCCAGCTCTGCTTGGAGGTCTCCAGAATAGGCTGGAGGC
HLADRB5INTRON1	GCATTCCTTGTCTGCTCACTTCAGTCCCTCTAGCCTTCTTGTCCCT
HLADRB4	CTGAAGTAGATGAACAGCCCTGTCCCCAGGAAGAGCAGGCCAGCACAAA

✖ Overrepresented sequences

Sequence	Count	Percentage	Possible Source
GATCGGAAGAGCACACGTCTGAACCTCAGTCAGTCTATGAATCTGTAT	7459	2.67885361298664	TruSeq Adapter, Index 6 (97% over 37bp)
NN	2629	0.9441890532969401	No Hit
GGCAGACAGTGTGACAAAGAGGCTGGTAGGAGAAGAGGGATCAGGACG	677	0.24314035339750034	HLAB5'UTR (100% over 50bp)
TGGATACTCACGACGCCAGTCTCACTCCCATTGGGTGTCGGGTT	580	0.20830340468323516	HLAA5'UTR (100% over 50bp)
CTCATCTTCTGCCTCTCCATTTCCTGCTTGTATAGTTCAAGTCCCTCTA	426	0.15299525930182445	HLADRB1INTRON1 (100% over 50bp)
CTCATCTTCTGCCTCTCCATTTCCTGCTTGTATACCTCAGTCCCTCTA	406	0.14581238327826462	HLADRB1INTRON1 (98% over 50bp)
GCAGGTGCCTTGCAGAACAAAGTCAGGGTTCTCAAGTCACAAAGGGA	400	0.14365752047119665	HLAA3'UTR (100% over 50bp)
CTGGGGAGGAAACACAGGTCAAGCATGGAACAGGGTCACAGTGGACACG	294	0.10558827754632956	HLAB3'UTR (100% over 50bp)

✖ Overrepresented sequences



Sequence	Count	Percentage	Possible Source
GATCGGAAGAGCACACGTCTGAACCTCAGTCAGTCTATGAATCTGTAT	5189	1.2673902848880378	TruSeq Adapter, Index 11 (97% over 38bp)
NN	1483	0.36221618664269806	No Hit
CTCATCTTCTGCCTCTCCATTTCCTGCTTGTATAGTTCAAGTCCCTCTA	1148	0.28039391926218293	HLADRB1INTRON1 (100% over 50bp)
CTCATCTTCTGCCTCTCCATTTCCTTACCTACATCAGCCCTCTA	466	0.11381843760991052	HLADRB1INTRON1 (96% over 30bp)

- E' stato verificato che nella maggioranza delle sedute analizzate i contaminati facevano riferimento sempre alle stesse sequenze;
- È stata creata una lista di sequenze contaminanti da inserire nelle impostazioni del software per verificare la presenza di questi contaminati nelle successive sedute.

E' emerso come nella metodica in uso siano le regioni 5' e 3' UTR della prima classe e l'introne 1 dei loci DRB3/4/5 a creare contaminazione. E' possibile utilizzare questo strumento nella determinazione di un eventuale mix-up.

Conclusioni

- La metodica descritta si propone come supporto nella valutazione della qualità dei file FASTQ di sequenza, parametro che riveste particolare importanza nella routine laboratoristica.
- L' analisi in oggetto permette inoltre di caratterizzare i propri dati di sequenziamento in fase di validazione e affiancare i software commerciali nell'interpretazione del dato nella pratica lavorativa.



Grazie per l'attenzione

