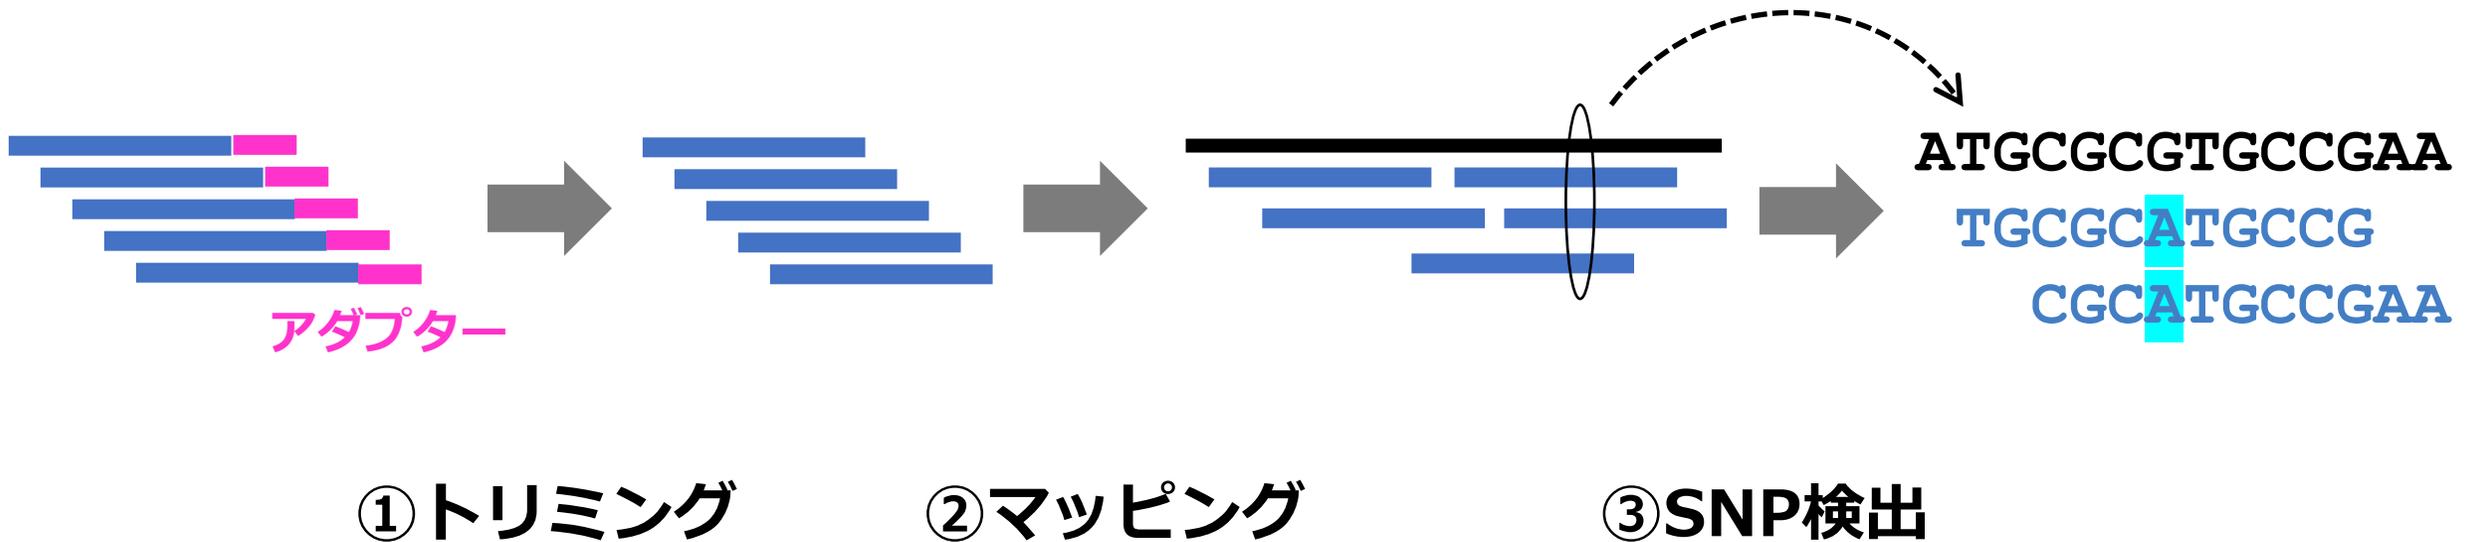


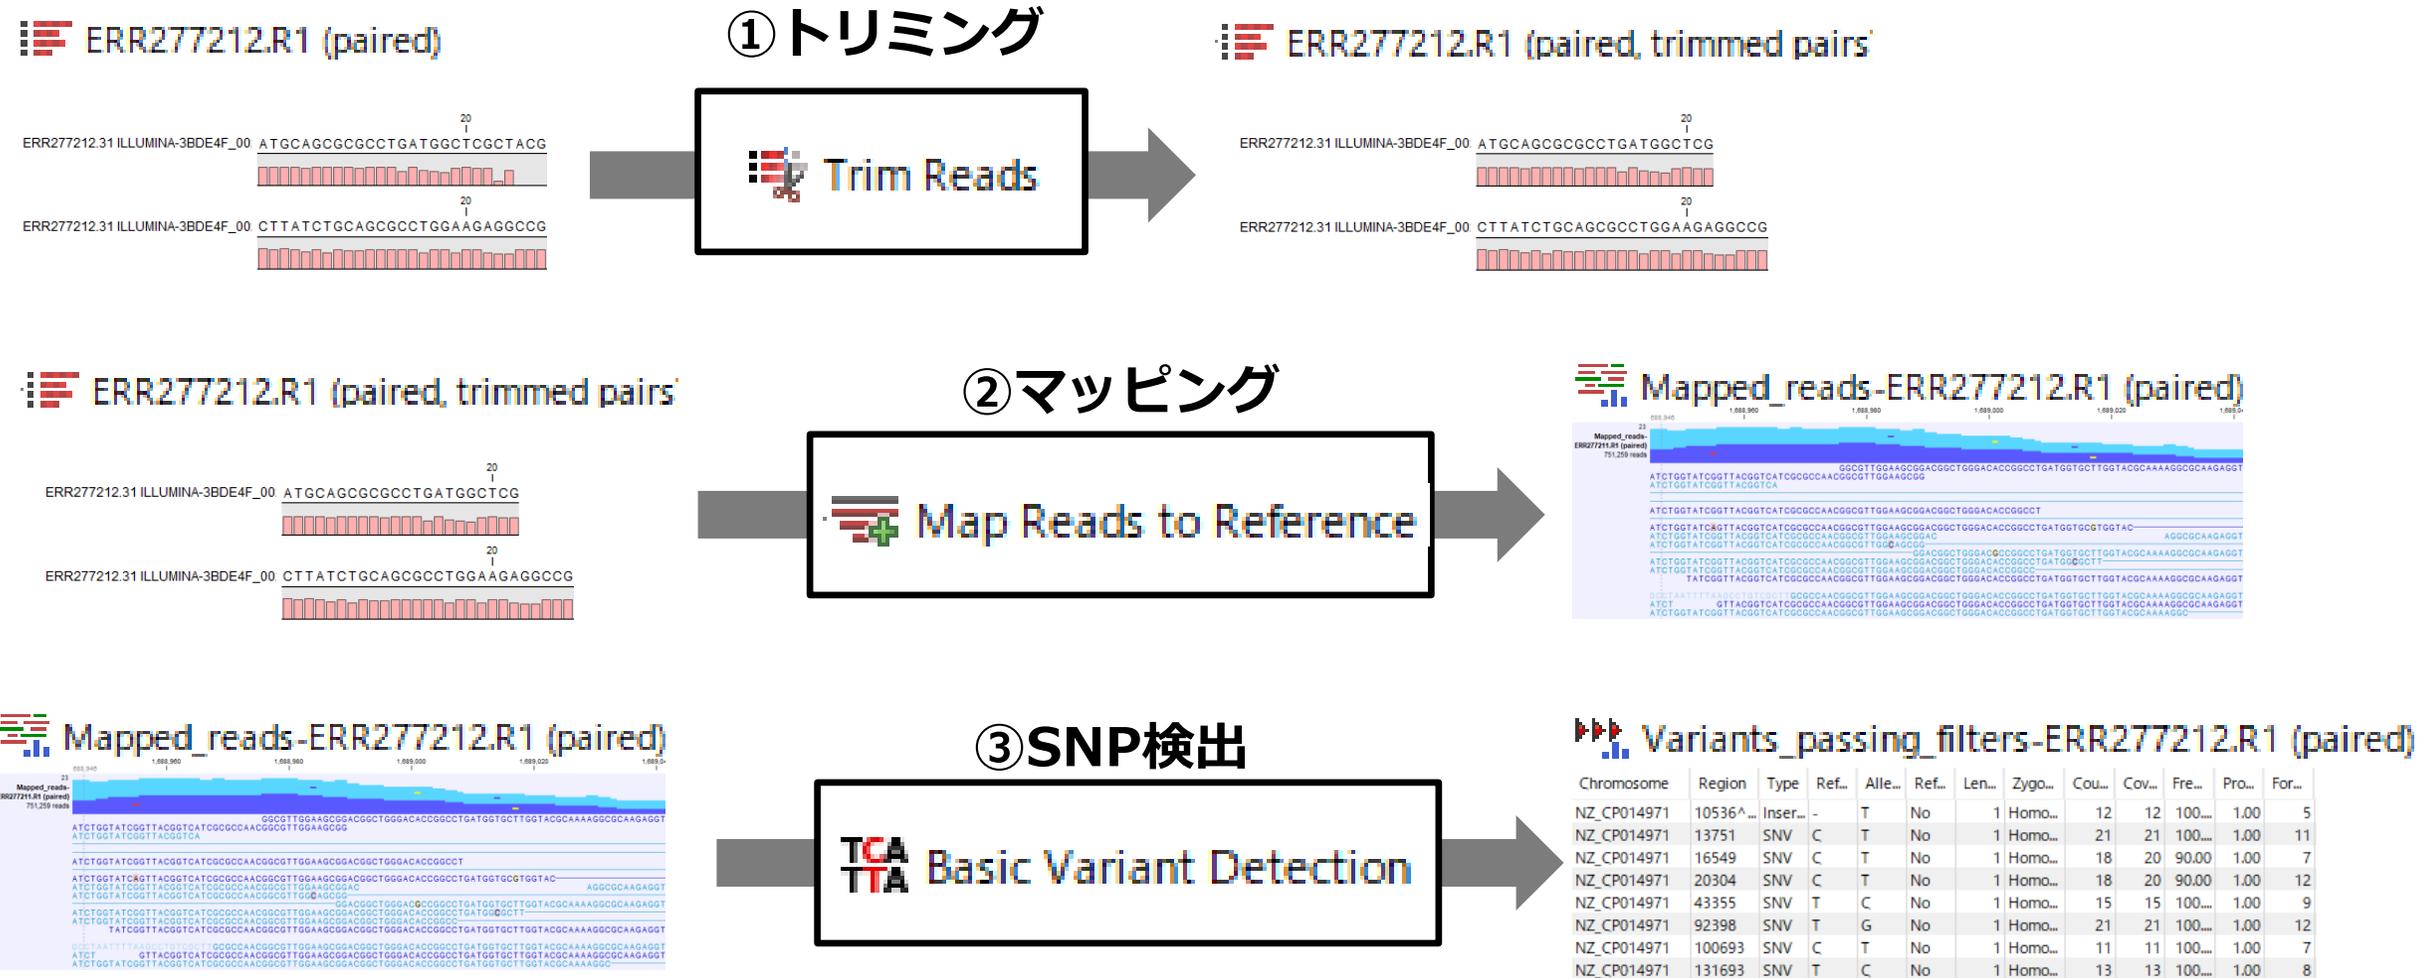
高度なワークフローを用いた 複雑なNGSデータ処理プロセスの自動化

フィルジェン株式会社 バイオインフォマティクス部
(support@filgen.jp)

解析フローの例 (SNP検出)

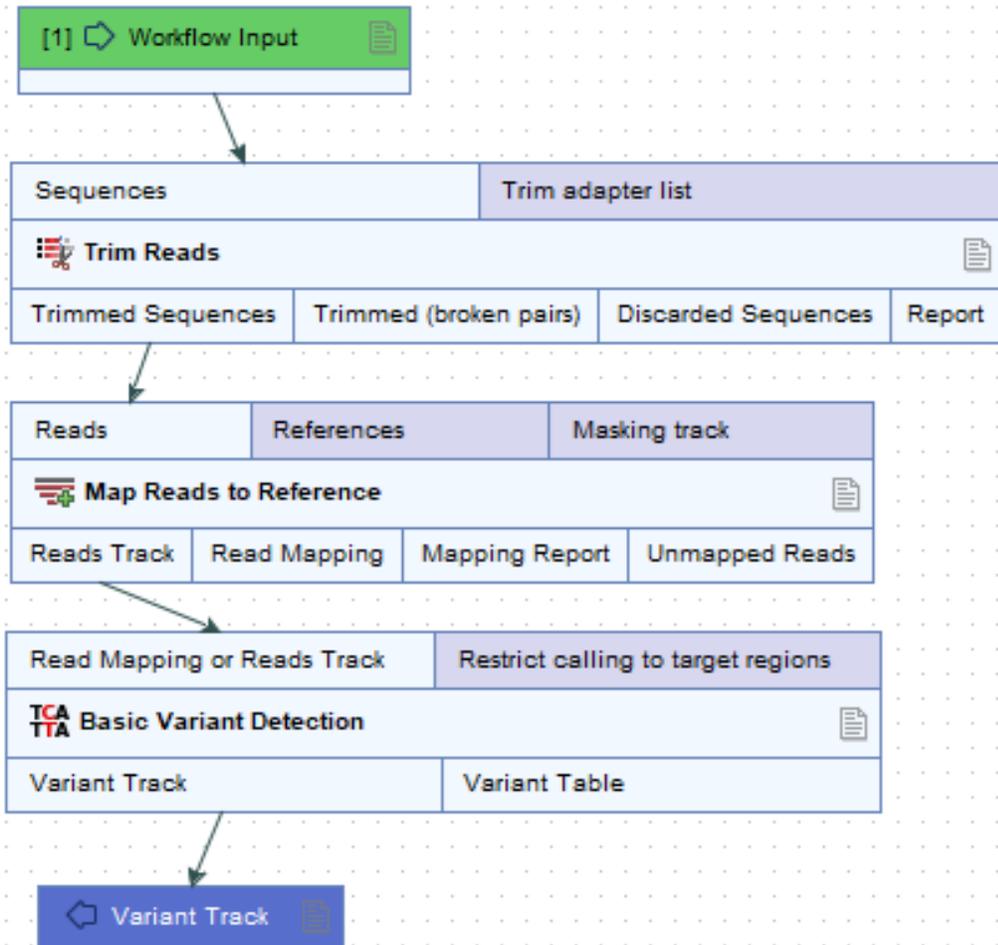


Genomics Workbench上での手順

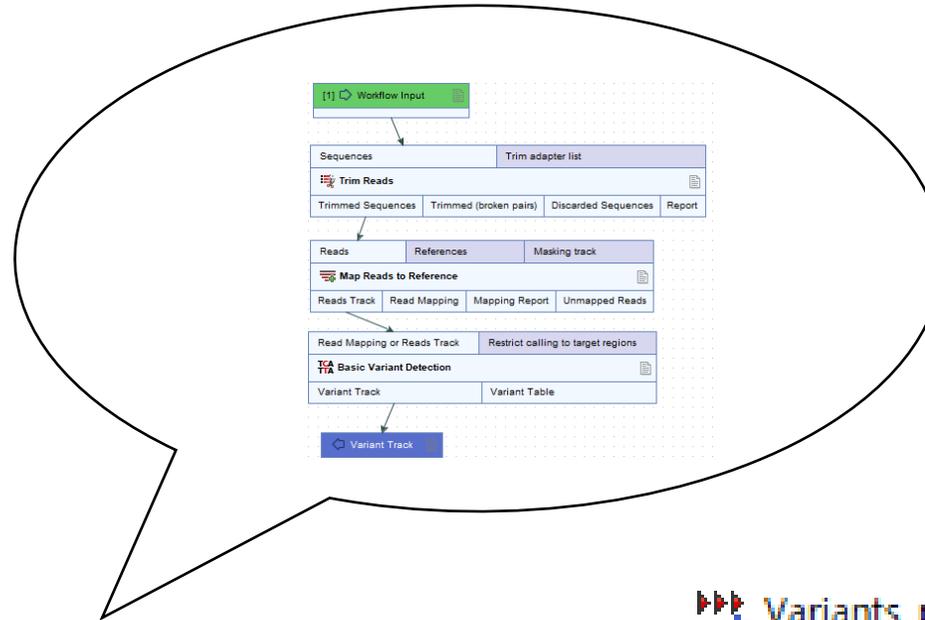


Chromosome	Region	Type	Ref...	Alle...	Ref...	Len...	Zygo...	Cou...	Cov...	Fre...	Pro...	For...
NZ_CP014971	10536^...	Inser...	-	T	No	1	Homo...	12	12	100...	1.00	5
NZ_CP014971	13751	SNV	C	T	No	1	Homo...	21	21	100...	1.00	11
NZ_CP014971	16549	SNV	C	T	No	1	Homo...	18	20	90.00	1.00	7
NZ_CP014971	20304	SNV	C	T	No	1	Homo...	18	20	90.00	1.00	12
NZ_CP014971	43355	SNV	T	C	No	1	Homo...	15	15	100...	1.00	9
NZ_CP014971	92398	SNV	T	G	No	1	Homo...	21	21	100...	1.00	12
NZ_CP014971	100693	SNV	C	T	No	1	Homo...	11	11	100...	1.00	7
NZ_CP014971	131693	SNV	T	C	No	1	Homo...	13	13	100...	1.00	8

ツールのフローを登録



 Trim, Map and Detect SNPs



ERR277212.R1 (paired)



Variants_passing_filters-ERR277212.R1 (paired)

Chromosome	Region	Type	Ref..	Alle..	Ref..	Len..	Zygo..	Cou..	Cov..	Fre..	Pro..	For..
NZ_CP014971	10536^...	Inser...	-	T	No	1	Homo...	12	12	100...	1.00	5
NZ_CP014971	13751	SNV	C	T	No	1	Homo...	21	21	100...	1.00	11
NZ_CP014971	16549	SNV	C	T	No	1	Homo...	18	20	90.00	1.00	7
NZ_CP014971	20304	SNV	C	T	No	1	Homo...	18	20	90.00	1.00	12
NZ_CP014971	43355	SNV	T	C	No	1	Homo...	15	15	100...	1.00	9
NZ_CP014971	92398	SNV	T	G	No	1	Homo...	21	21	100...	1.00	12
NZ_CP014971	100693	SNV	C	T	No	1	Homo...	11	11	100...	1.00	7
NZ_CP014971	131693	SNV	T	C	No	1	Homo...	13	13	100...	1.00	8

- ① トリミング
- ② マッピング
- ③ SNP検出

トリミングしたいリードデータが100個ある場合…

トリミングを100回実行するのは大変。

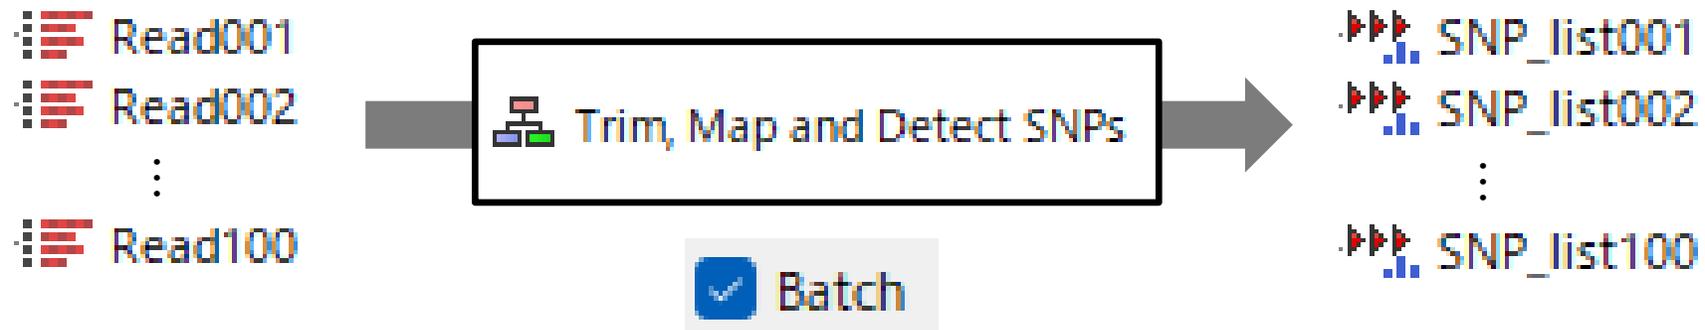


BatchモードをONにして100個のデータを指定すると、自動で1データずつ100回トリミングを行う。

→1回実行するだけでいい。

トリミング、マッピング、SNP検出したいリードデータが100個ある場合…

それぞれの工程を100回実行するのは、とても大変。

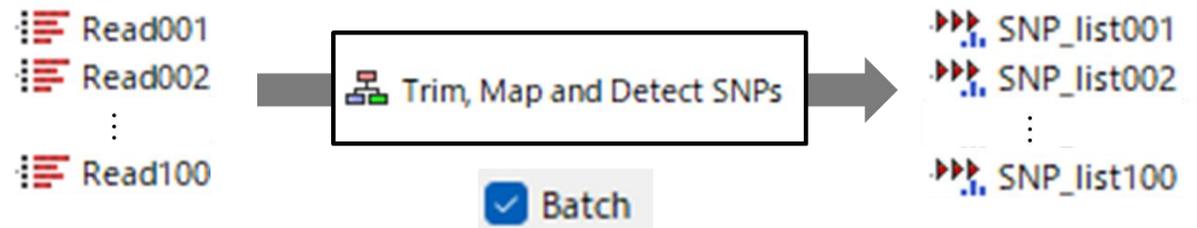
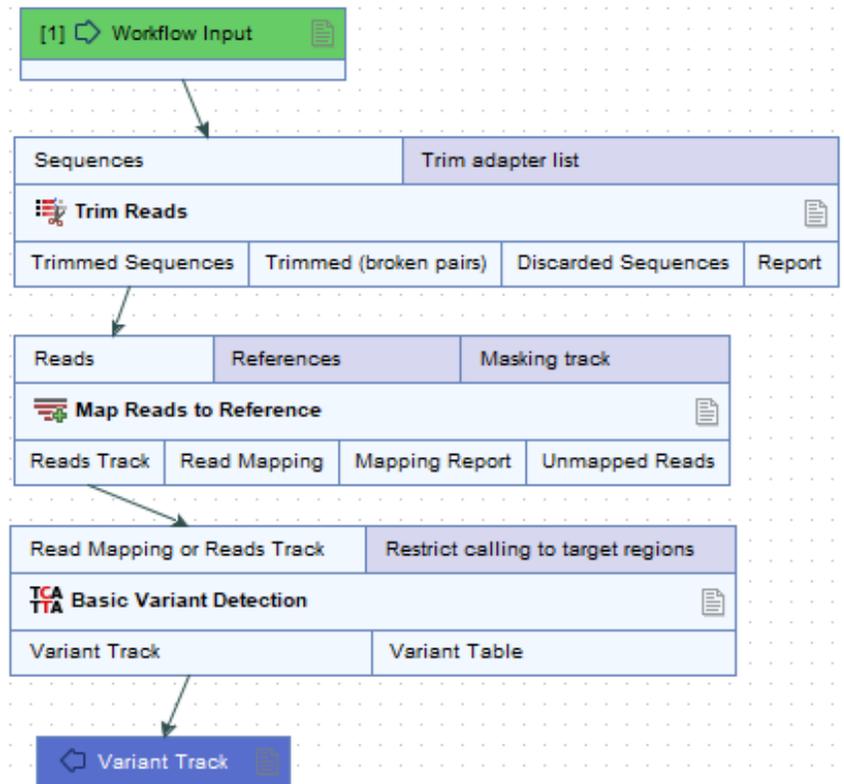


BatchモードをONにして100個のデータを指定すると、自動で1データずつトリミング・マッピング・SNP検出を行う。

→1回実行するだけでいい。

全てのリードに対して、同じリファレンス配列を使う場合は簡単。

最初にリファレンス配列を 1 個指定して、
それに各リードデータのマッピングを繰り返すだけでいい。



毎回入力異なるだけで、中でやることは一緒（単純な反復作業）

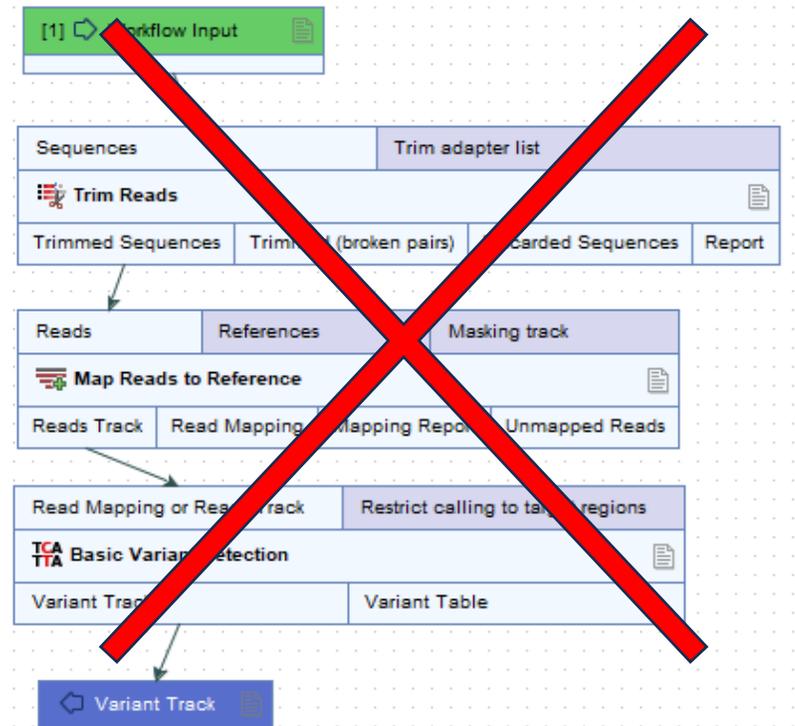
リードに応じてマッピングしたいリファレンスが異なる場合はより複雑。

どのリードをどのリファレンスにマッピングするかをソフトウェアに教える必要がある。

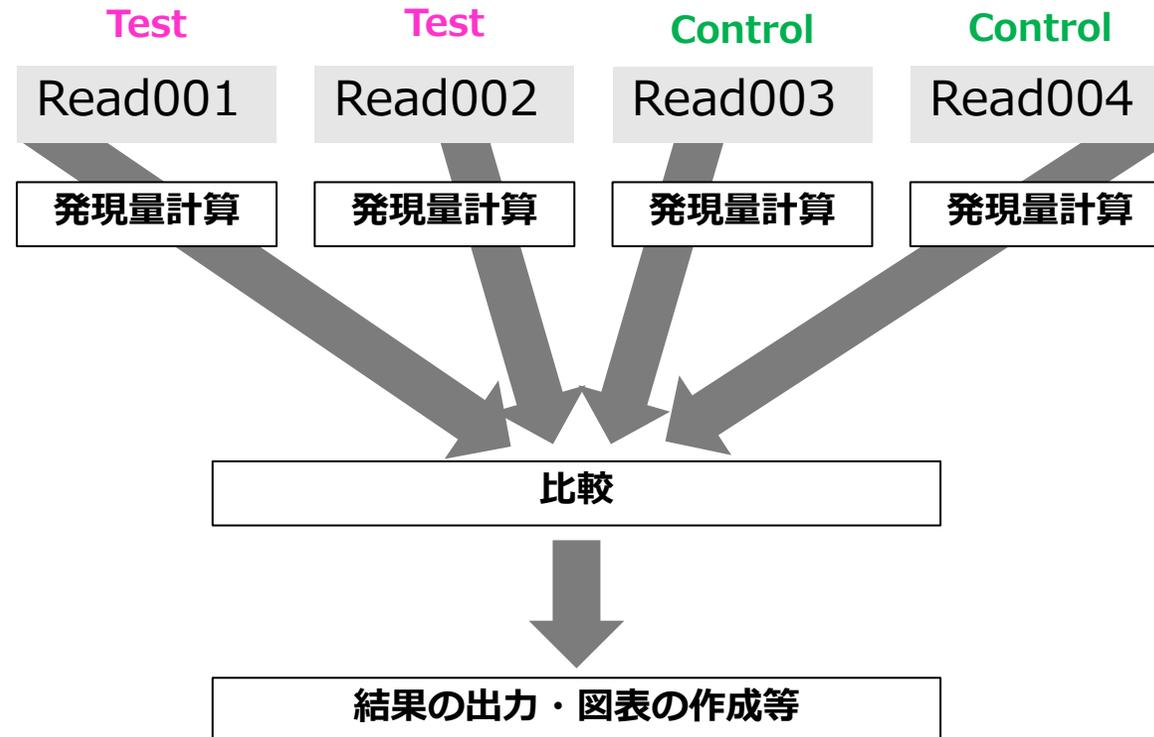
(例)

Read001～Read020 : リファレンスAにマッピングしてSNP検出
Read021～Read040 : リファレンスBにマッピングしてSNP検出
Read041～Read060 : リファレンスCにマッピングしてSNP検出
Read061～Read080 : リファレンスDにマッピングしてSNP検出
Read081～Read100 : リファレンスEにマッピングしてSNP検出

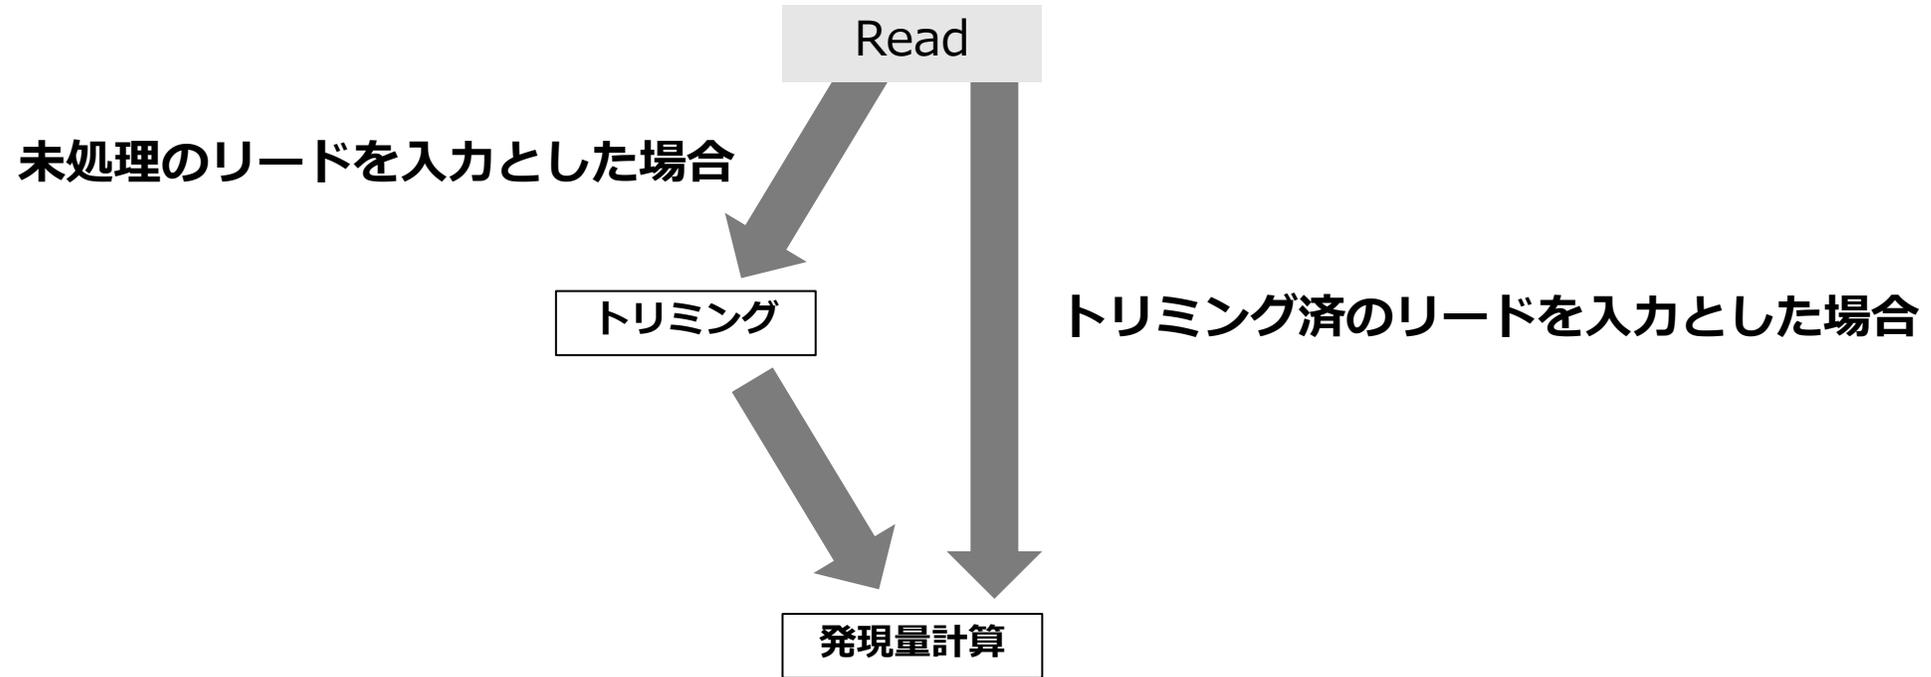
入力に応じて、中でやることも異なるため単純な反復作業にならない
→制御要素を含める必要がある。

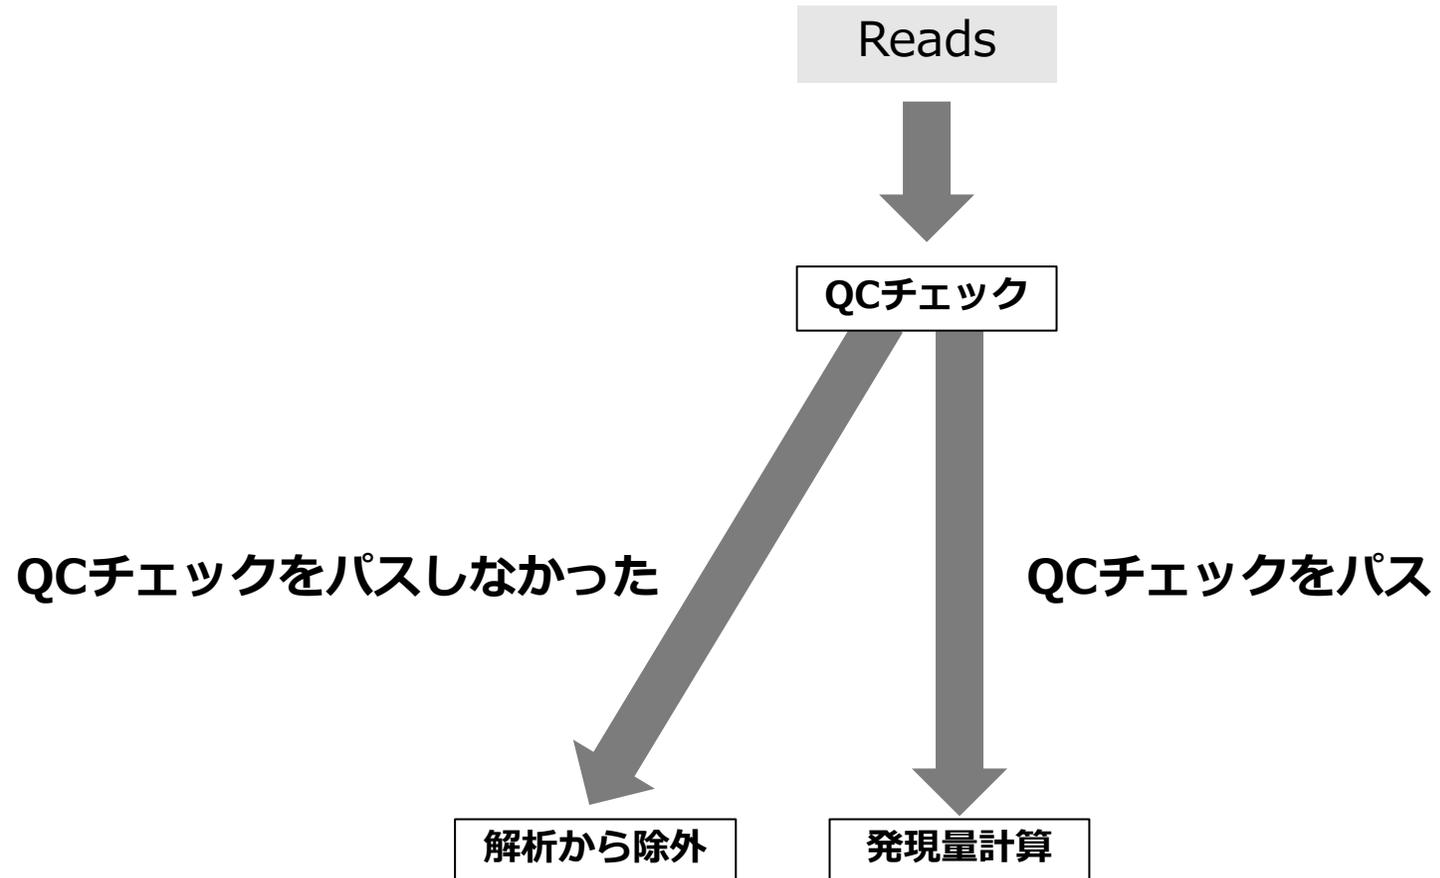


各リードについて、遺伝子発現量を計算した後、比較を行う場合。



一本道ではないため、単純なワークフローでは対応できない。





リードに応じてマッピングしたいリファレンスが異なる場合はより複雑。

どのリードをどのリファレンスにマッピングするかをソフトウェアに教える必要がある。

(例)

Read001～Read020 : リファレンスAにマッピングしてSNP検出

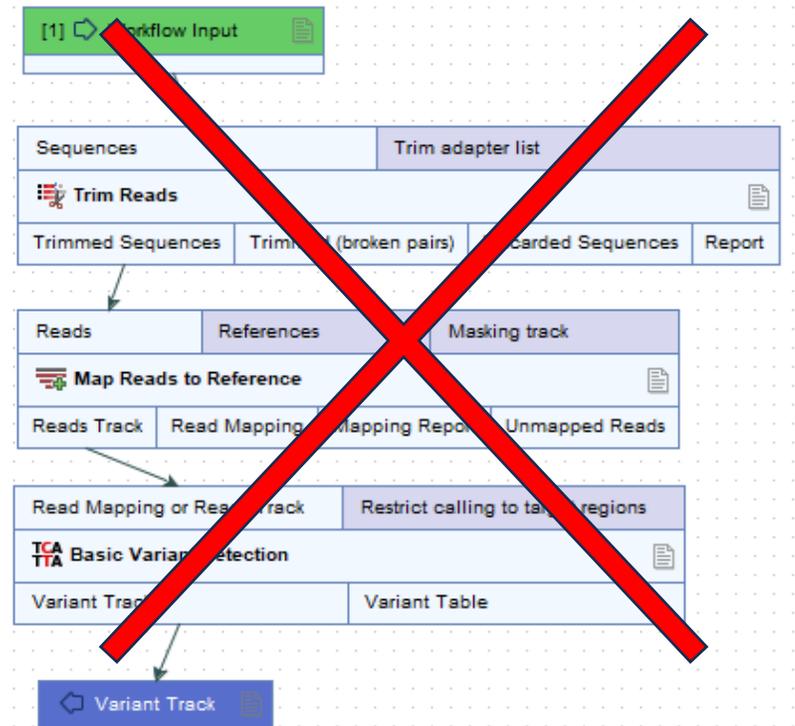
Read021～Read040 : リファレンスBにマッピングしてSNP検出

Read041～Read060 : リファレンスCにマッピングしてSNP検出

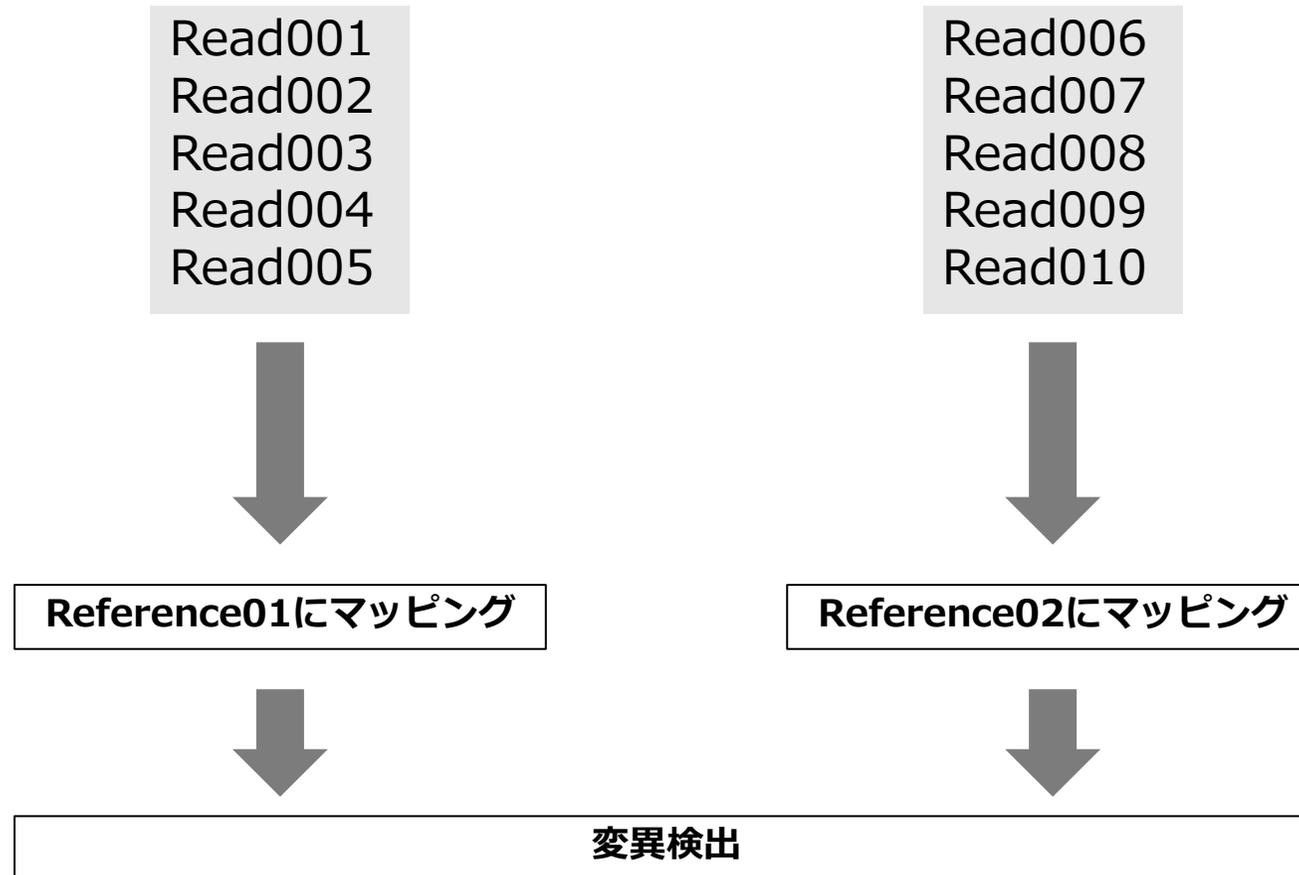
Read061～Read080 : リファレンスDにマッピングしてSNP検出

Read081～Read100 : リファレンスEにマッピングしてSNP検出

入力に応じて、中でやることも異なるため単純な反復作業にならない
→制御要素を含める必要がある。



パターン1:入力に応じてリファレンスが異なる



事前に2つのメタデータを用意し、インポートする必要がある。

Read_metadata

	A	B	C	D
1	Name	Prefecture	Sex	Reference
2	Read001	Aichi	F	Reference01
3	Read002	Mie	M	Reference01
4	Read003	Mie	M	Reference01
5	Read004	Gifu	M	Reference01
6	Read005	Aichi	F	Reference01
7	Read006	Mie	F	reference02
8	Read007	Gifu	M	reference02
9	Read008	Gifu	F	reference02
10	Read009	Aichi	M	reference02
11	Read010	Aichi	F	reference02

 read_metadata

Reference_metadata

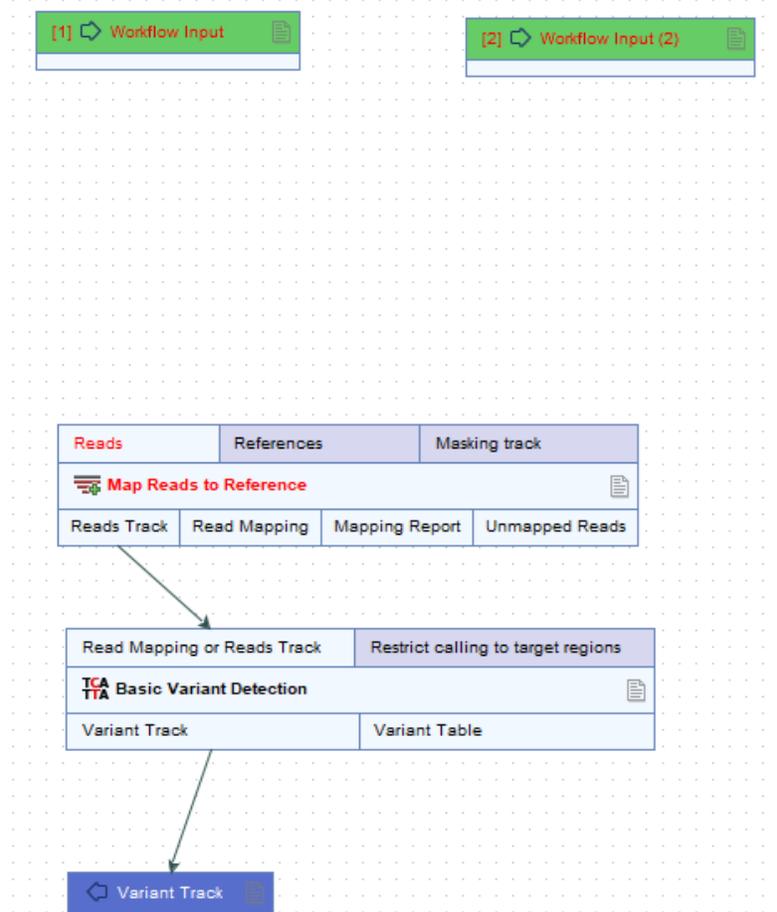
	A
1	Reference
2	Reference01
3	reference02

 reference_metadata

①リードデータに対するメタデータ

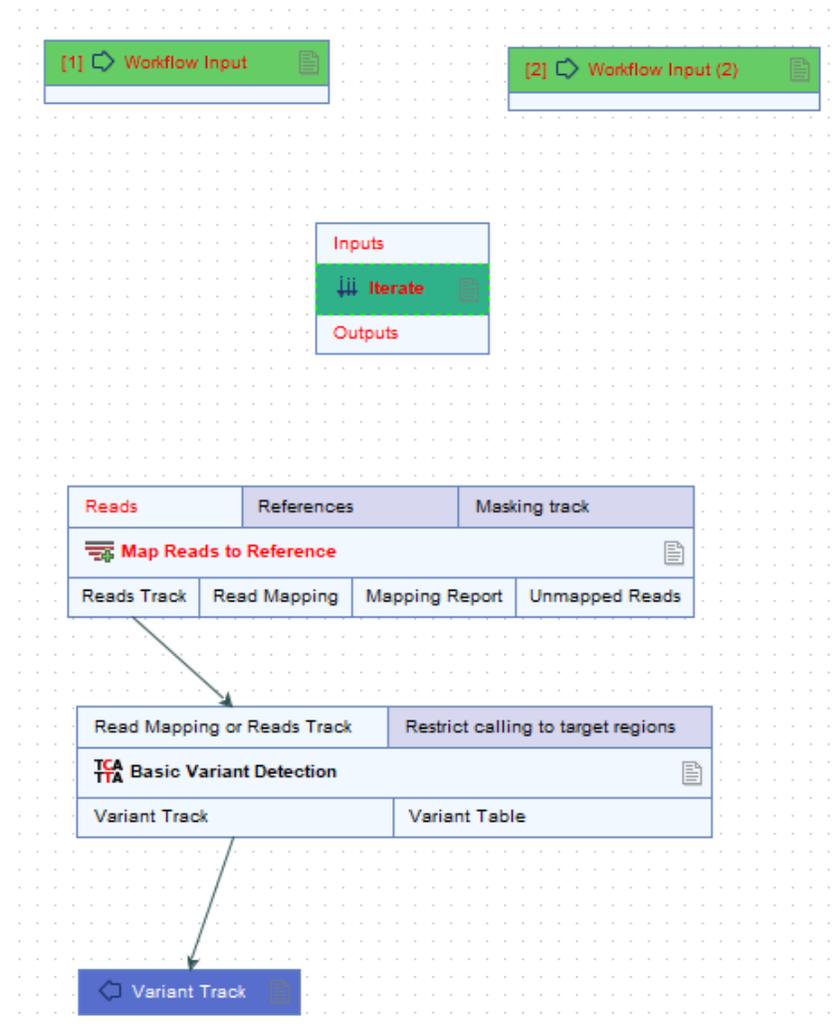
②リファレンスデータに対するメタデータ

パターン1:入力に応じてリファレンスが異なる



まずはリードとリファレンスに対応するInput2つと、その他の要素を配置

パターン1:入力に応じてリファレンスが異なる



次に制御要素の1つのである“Iterate”を配置

パターン1:入力に応じてリファレンスが異なる

Configure Iterate

1. Settings (Iterate)

Settings

Settings

Number of coupled inputs

Error handling

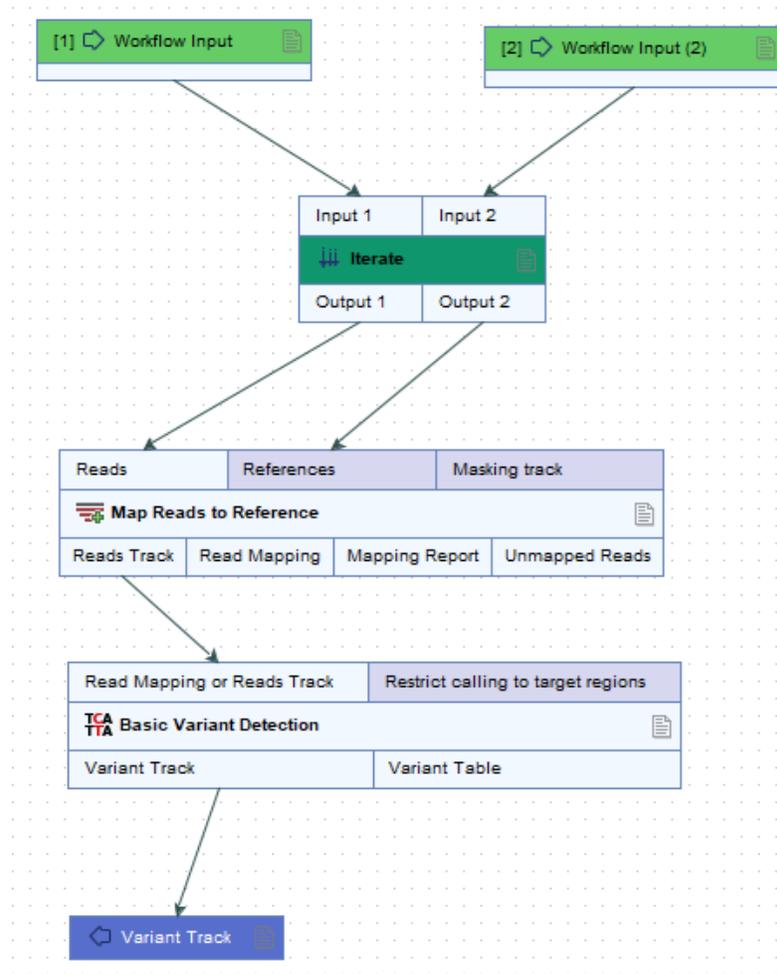
Metadata table columns

Primary input channel

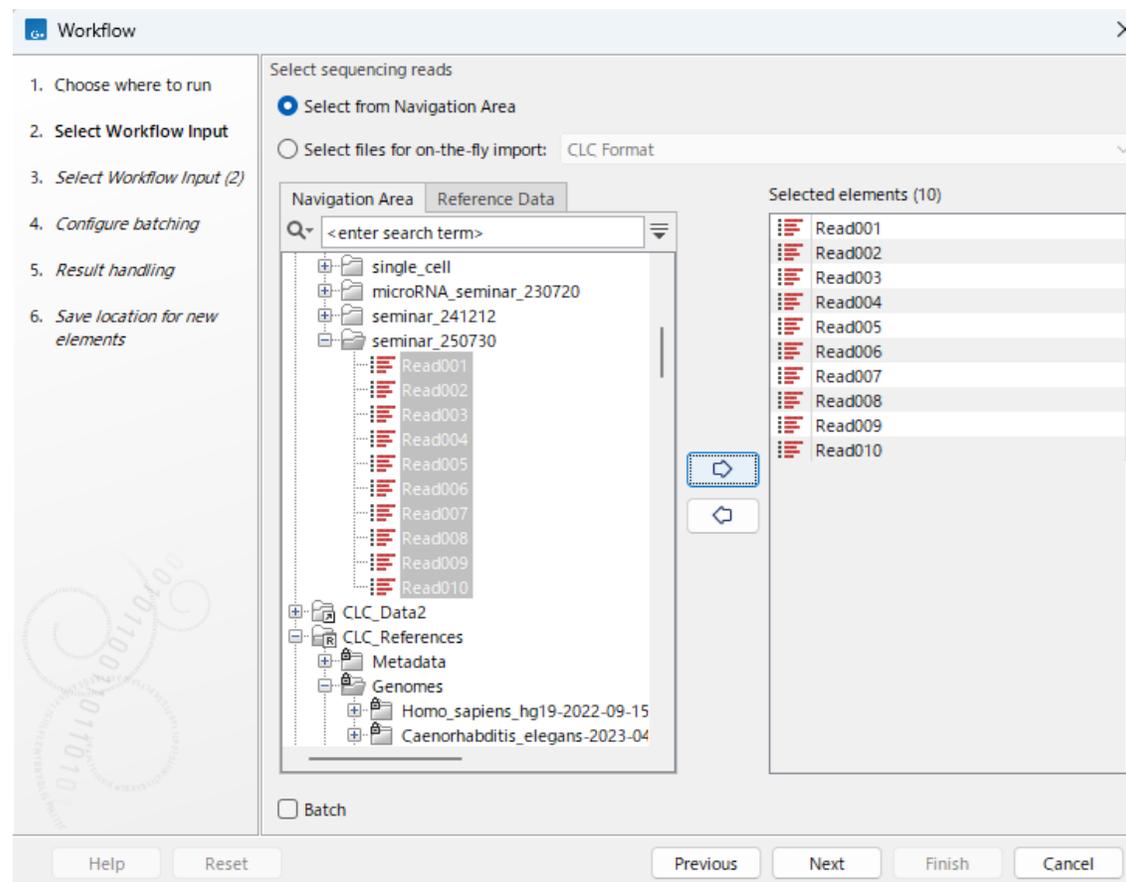
Help Reset Previous Next Finish Cancel

Number of coupled inputsを"2"とする。
(ReadとReferenceの2種類のデータを紐づけたい)

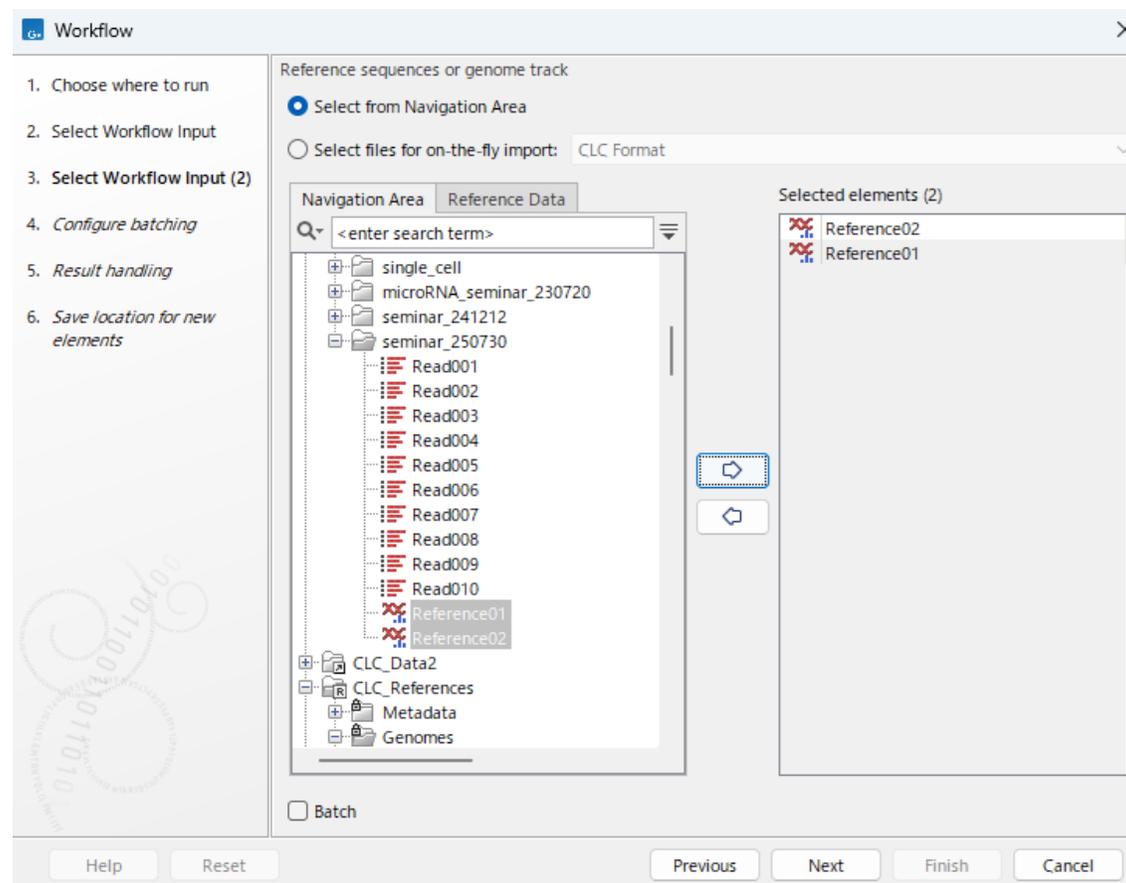
パターン1:入力に応じてリファレンスが異なる



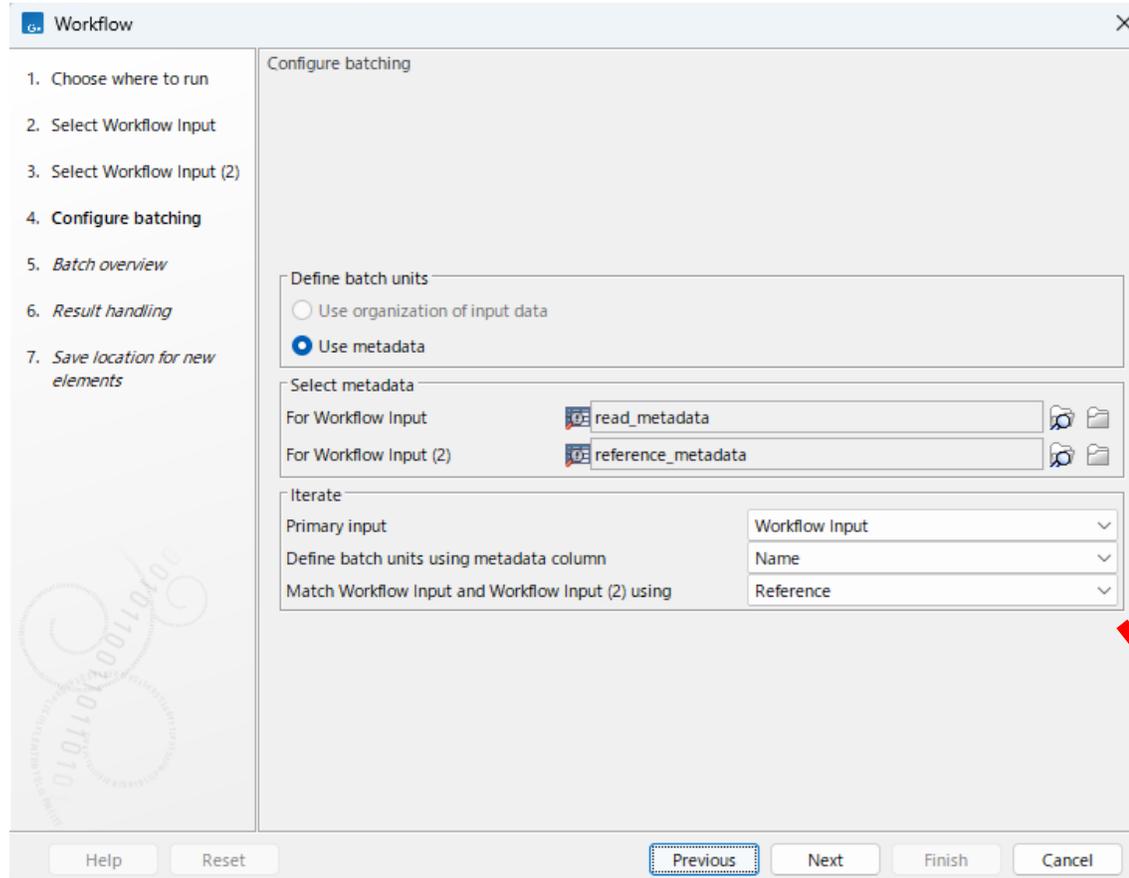
図のように線で結ぶと完成



まずは全てのリードデータを選択



次にすべてのリファレンスデータを選択



事前にインポートしたメタデータを指定

メタデータで繰り返しの単位を指定
今回は、リードごとにSNP解析を繰り返すので、
リード名を表すName列を指定

リファレンスとリードを紐づけるための列を指定

Workflow

Batch overview

Iterate (batch units from: Name)	Iterate (matching on: Reference)	Workflow Input	Workflow Input (2)
Read001	Reference01	Read001	Reference01
Read002	Reference01	Read002	Reference01
Read003	Reference01	Read003	Reference01
Read004	Reference01	Read004	Reference01
Read005	Reference01	Read005	Reference01
Read006	Reference02	Read006	Reference02
Read007	Reference02	Read007	Reference02
Read008	Reference02	Read008	Reference02
Read009	Reference02	Read009	Reference02
Read010	Reference02	Read010	Reference02

Only use elements containing:

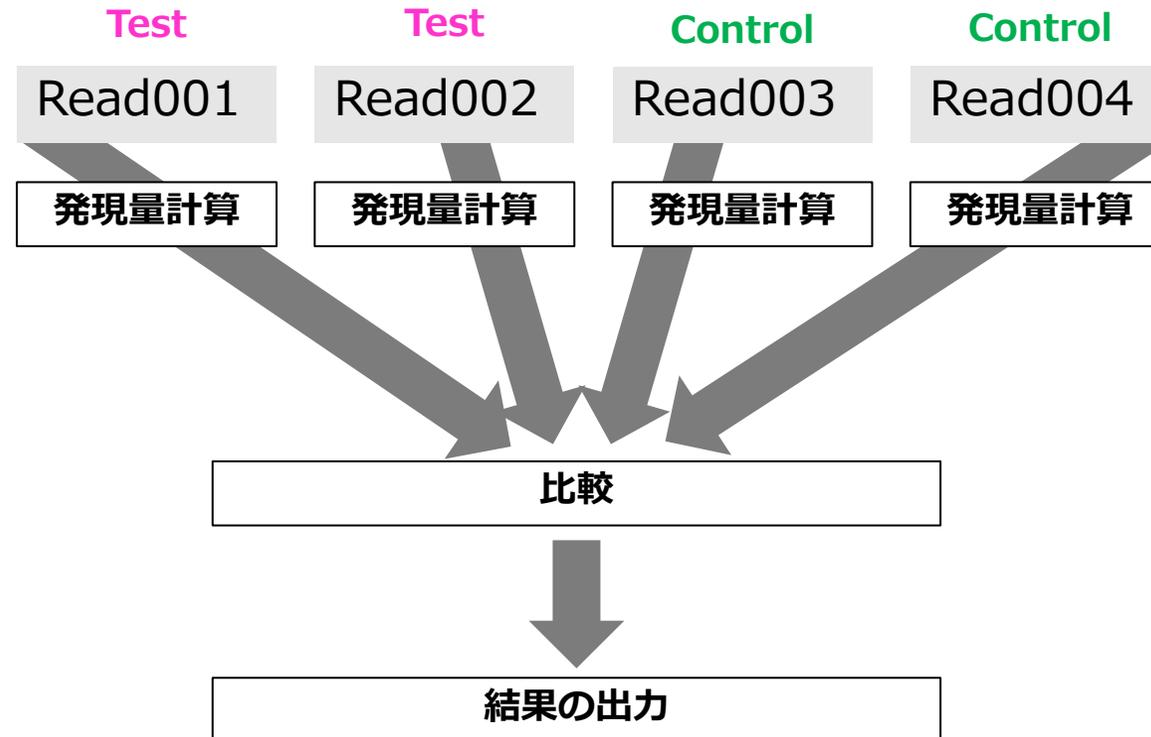
Exclude elements containing:

Help Reset Previous Next Finish Cancel

リードとリファレンスの対応に誤りがないかを確認

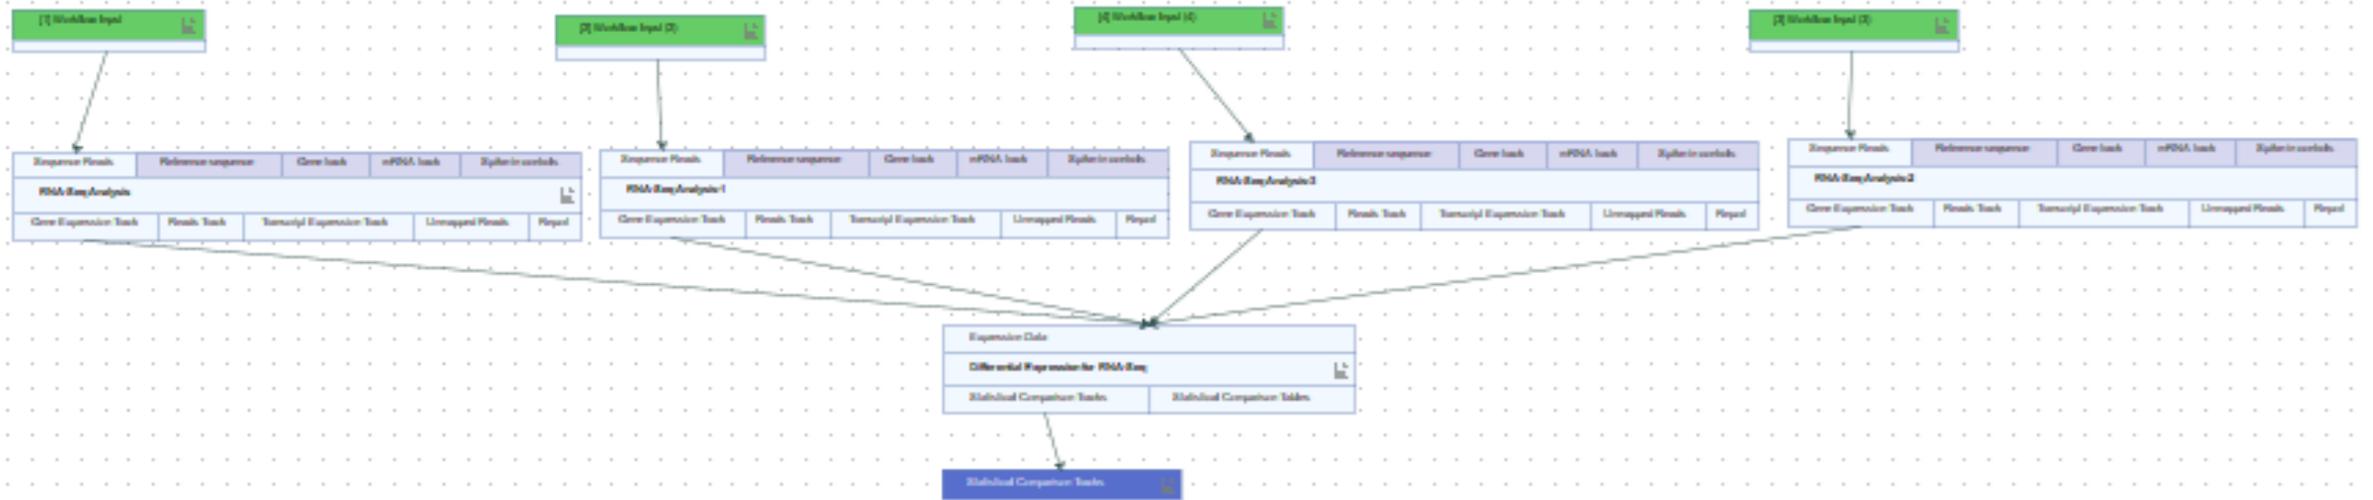
パターン2：個別に発現量の計算を行った後に統合

各リードについて、遺伝子発現量を計算した後、比較を行う場合。



一本道ではないため、単純なワークフローでは対応できない。

推奨されないワークフロー



サンプル数が4のときにしか対応できない

パターン2：個別に発現量の計算を行った後に統合

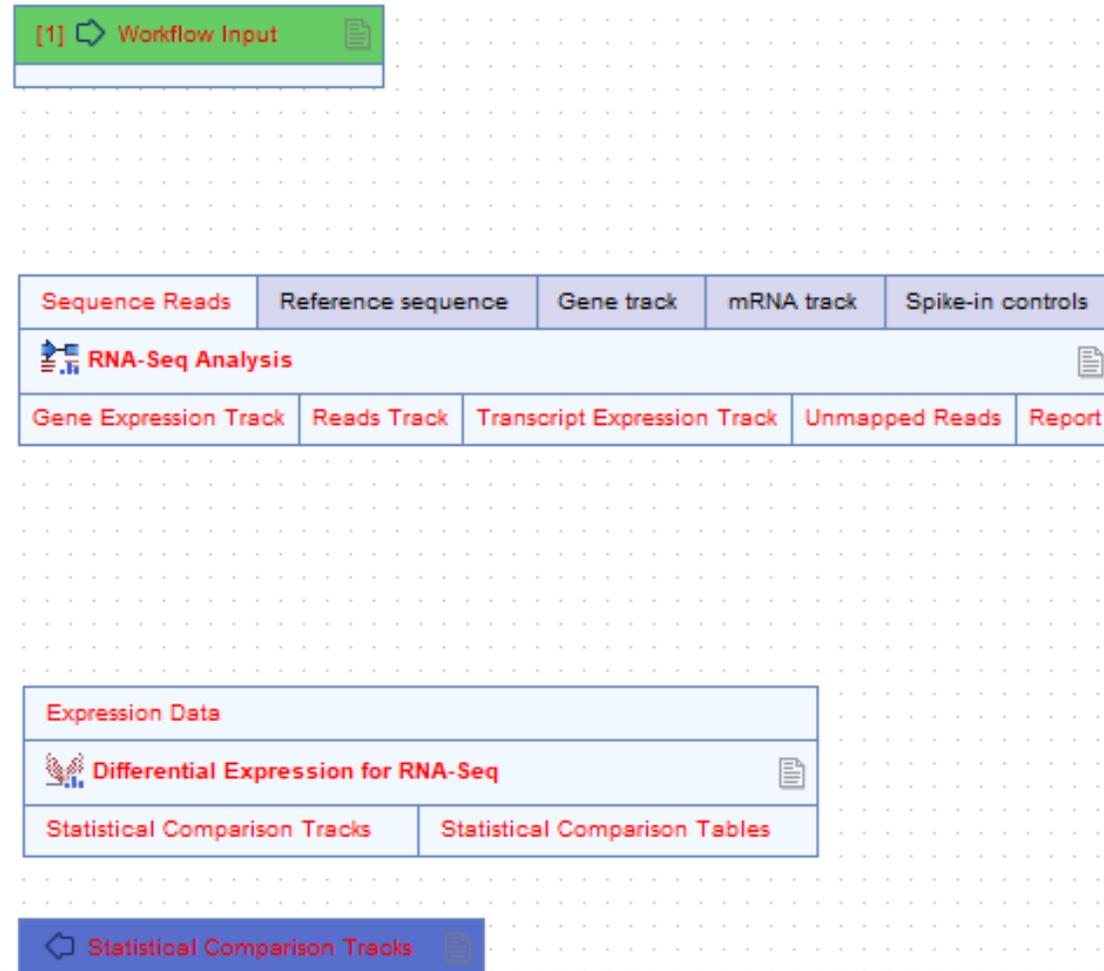


事前にメタデータを用意し、インポートする必要がある。

	A	B
1	Name	Group
2	Read001	Test
3	Read002	Test
4	Read003	Control
5	Read004	Control

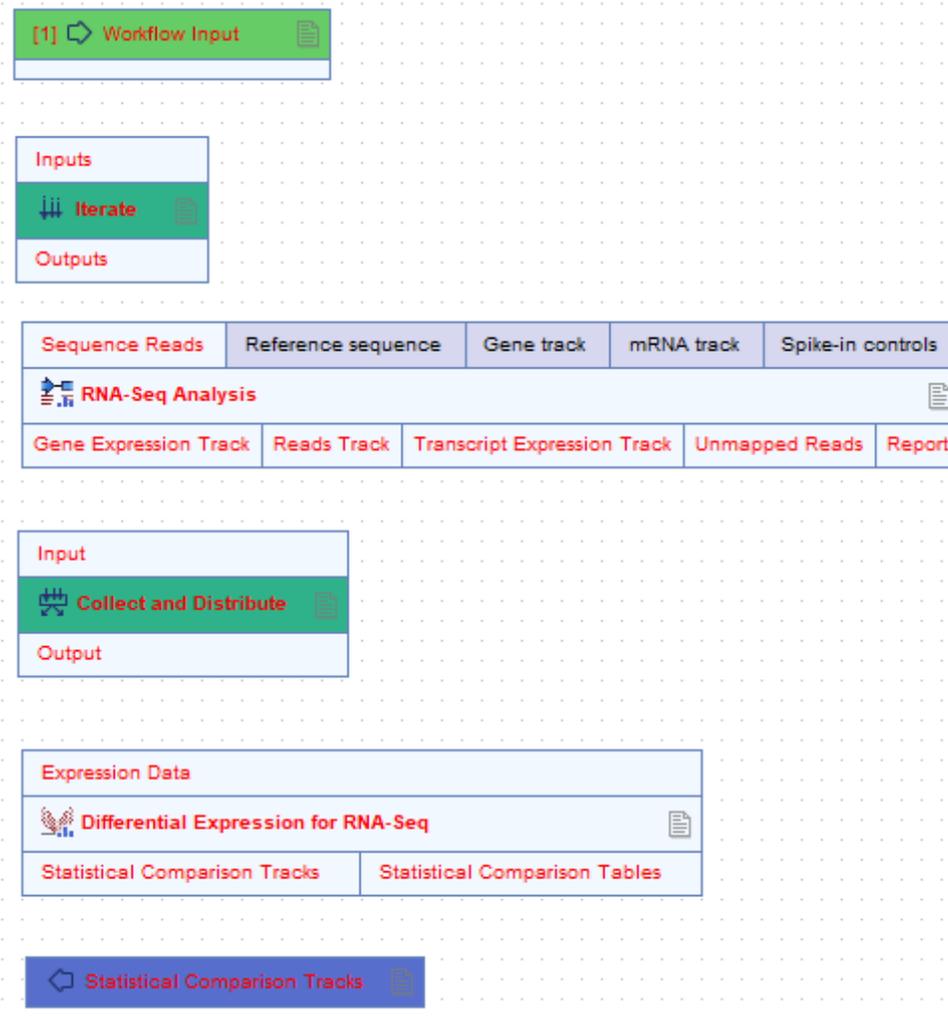
 read_comparison_metadata

パターン2：個別に発現量の計算を行った後に統合



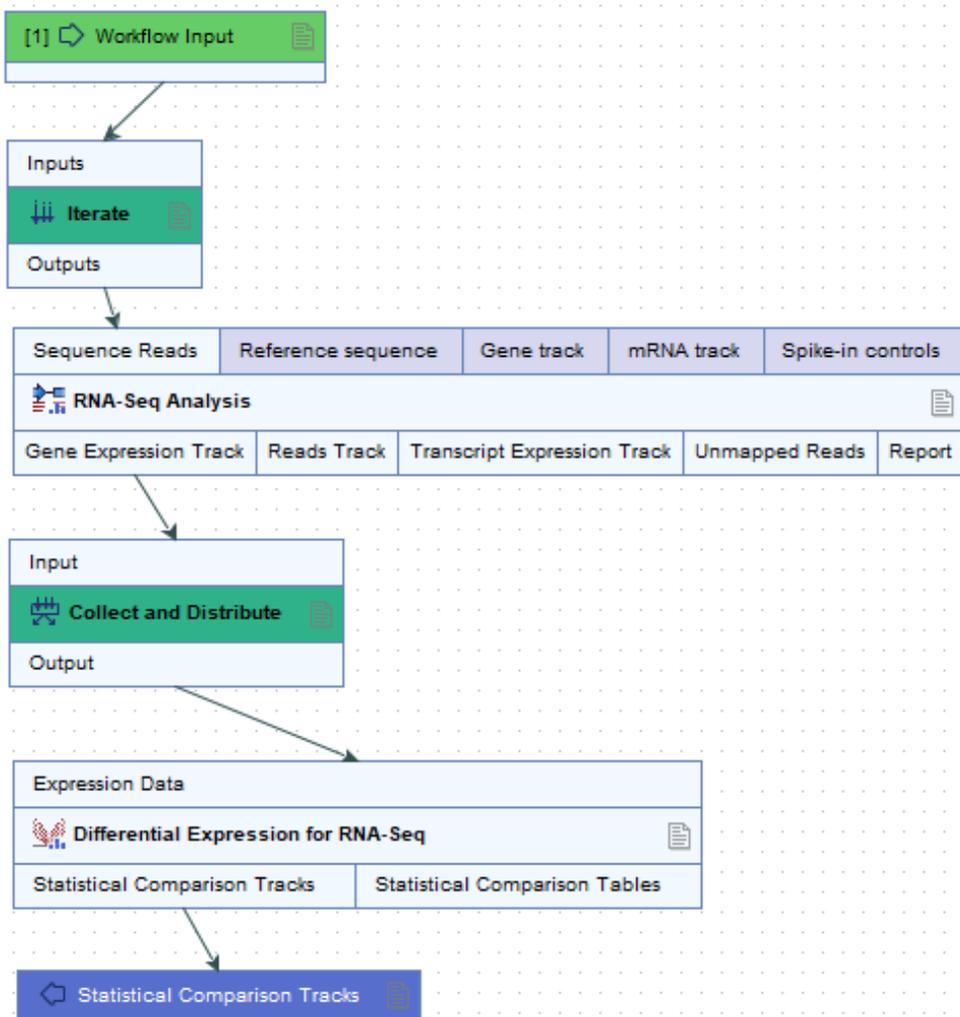
まずは各要素を配置

パターン2：個別に発現量の計算を行った後に統合



つぎに、RNA-seq Analysisを“Iterate”と“Collect and Distribute”ではさむ

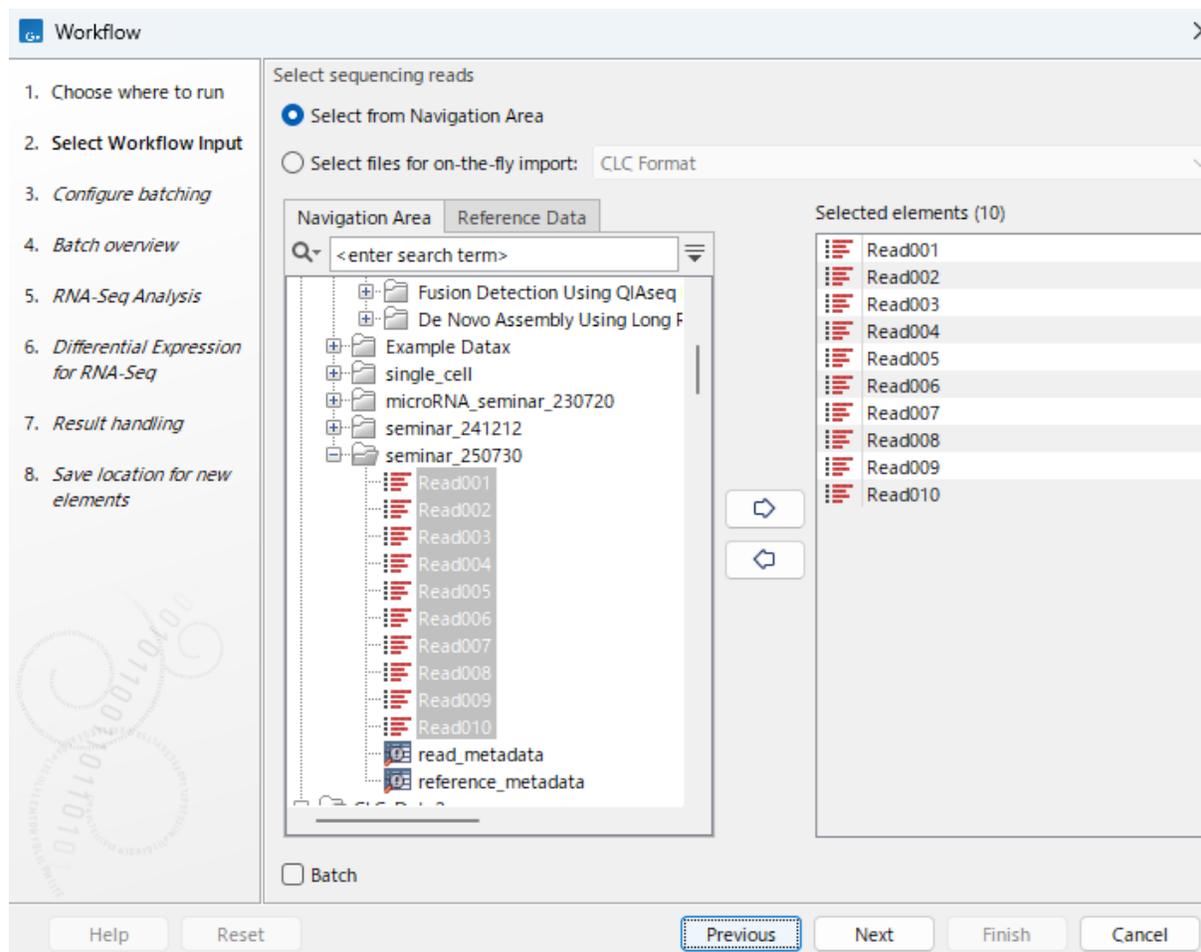
パターン2：個別に発現量の計算を行った後に統合



“Iterate”と“Collect and Distribute”で挟まれた部分が繰り返される。

繰り返し部分の解析が全入力に対して終了したら、出揃ったデータを次のツールに入力する。

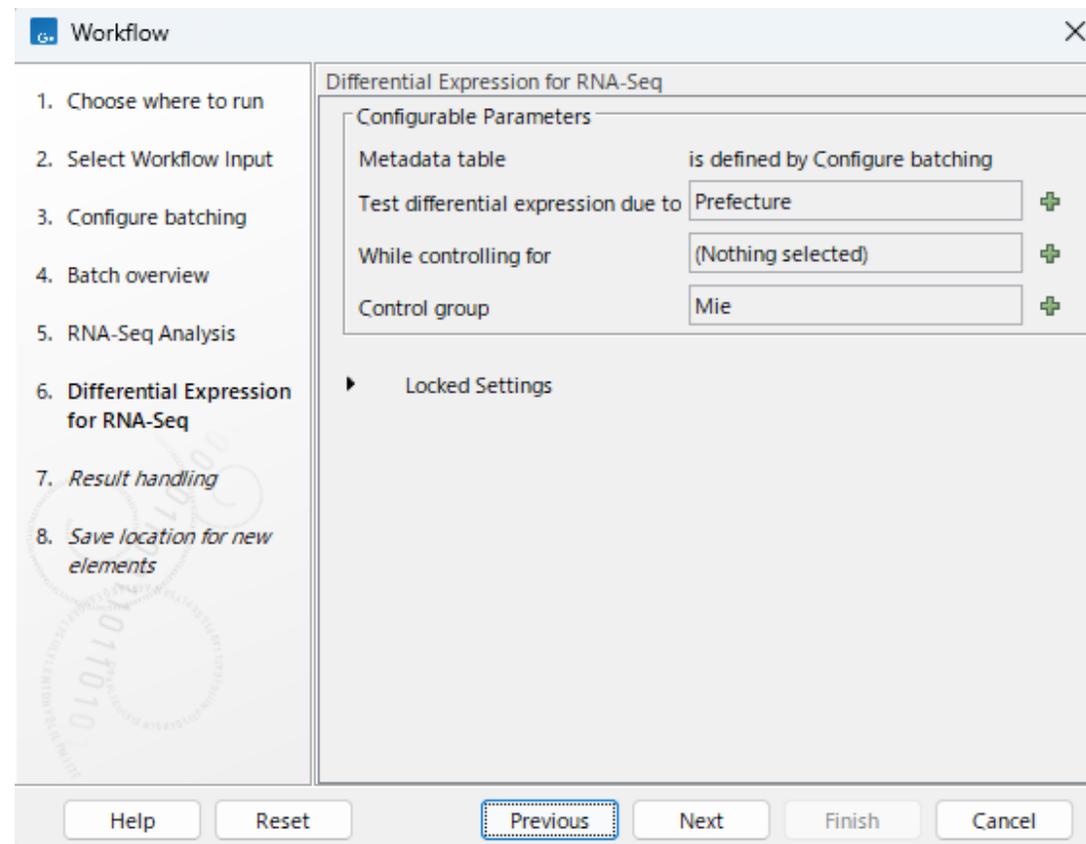
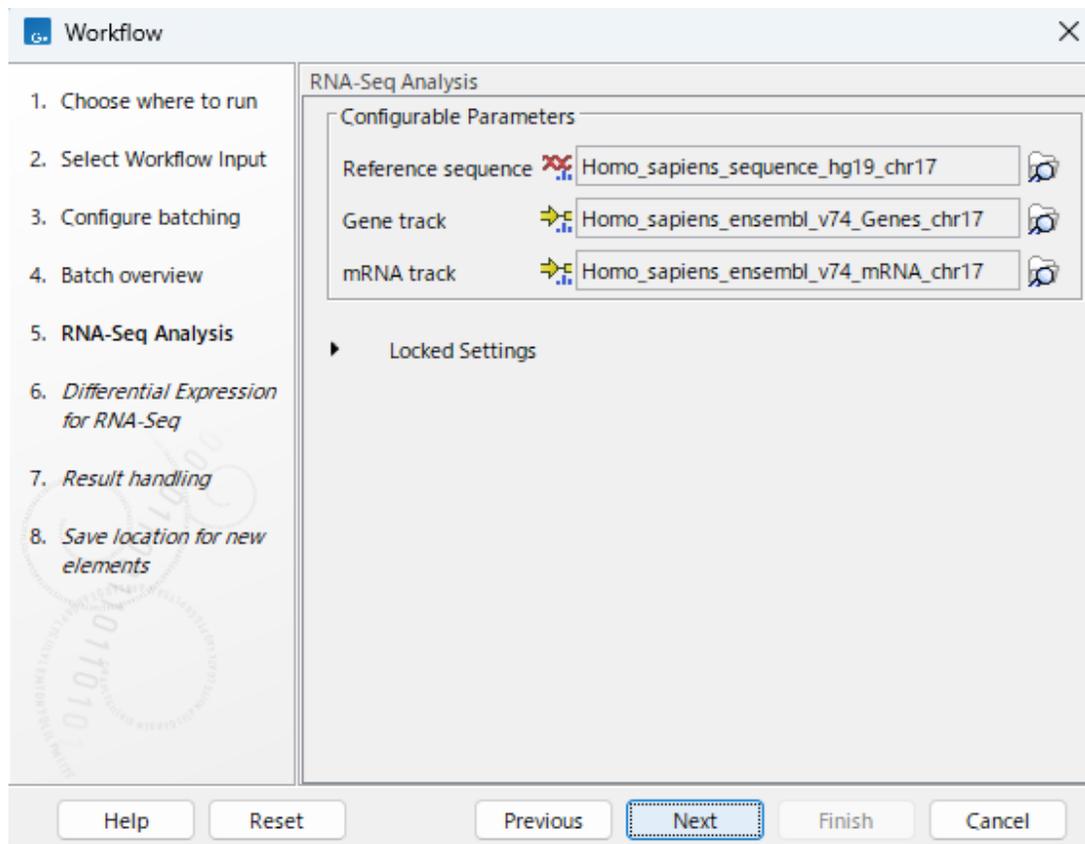
図のように矢印で結ぶ



全リードデータを指定する
("Batch"オプションは指定しない)

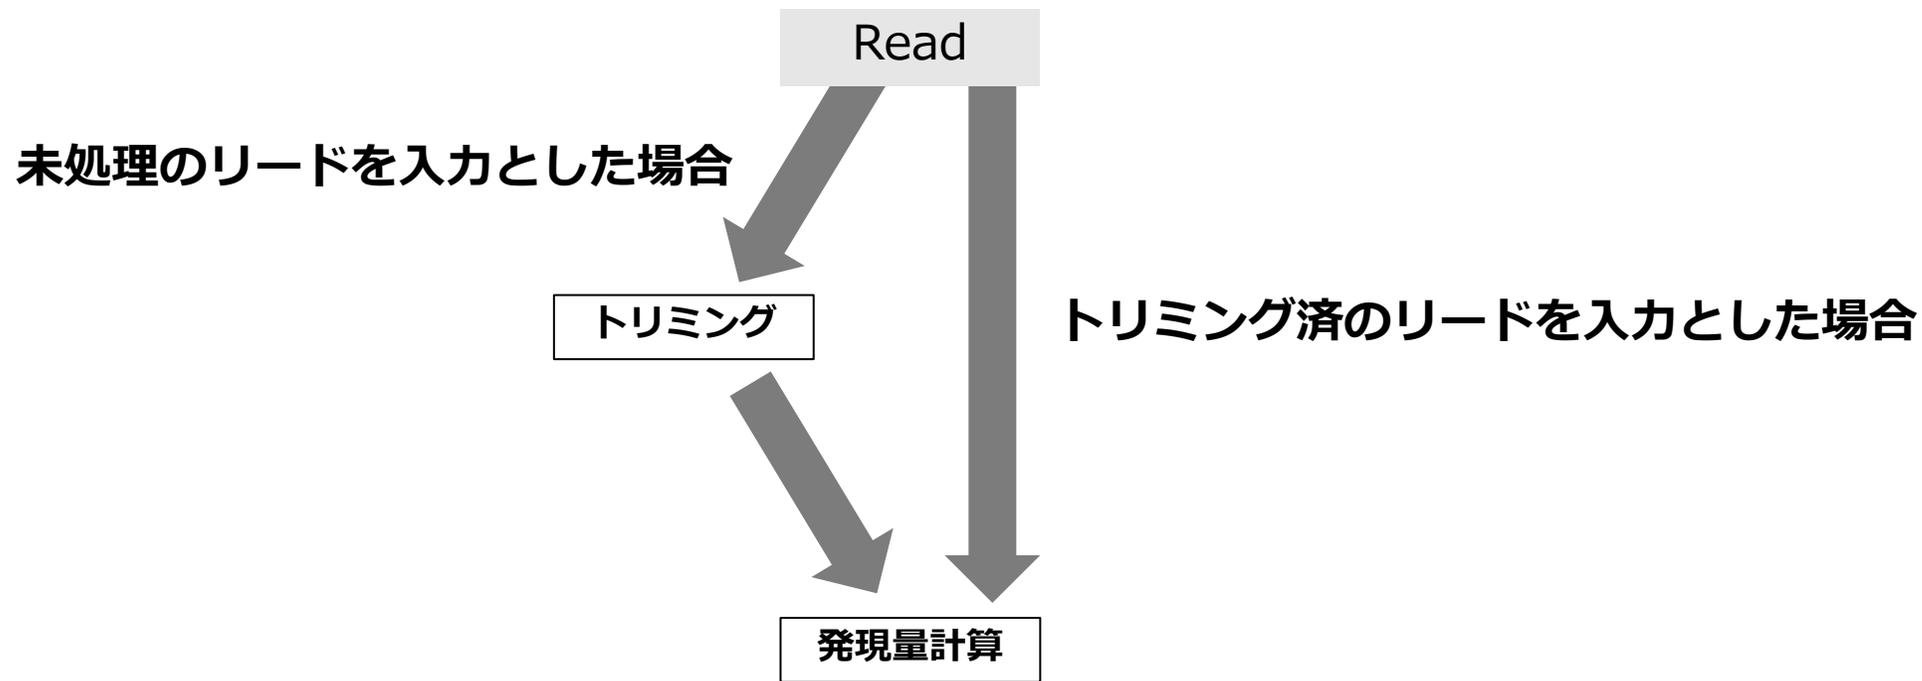
The screenshot shows a 'Workflow' configuration window with a sidebar on the left and a main configuration area on the right. The sidebar lists seven steps: 1. Choose where to run, 2. Select Workflow Input, 3. Configure batching (highlighted), 4. RNA-Seq Analysis, 5. Differential Expression for RNA-Seq, 6. Result handling, and 7. Save location for new elements. The main area is titled 'Configure batching' and contains three sections: 'Define batch units' with radio buttons for 'Use organization of input data' and 'Use metadata' (selected); 'Select metadata' with a text box containing 'read_metadata' and folder selection icons; and 'Iterate' with a label 'Define batch units using metadata column' and a dropdown menu showing 'Name'. At the bottom, there are buttons for 'Help', 'Reset', 'Previous', 'Next', 'Finish', and 'Cancel'.

Define batch unitsで“Use metadata”を選択し、各リードが属する群の情報を記述したメタデータを指定

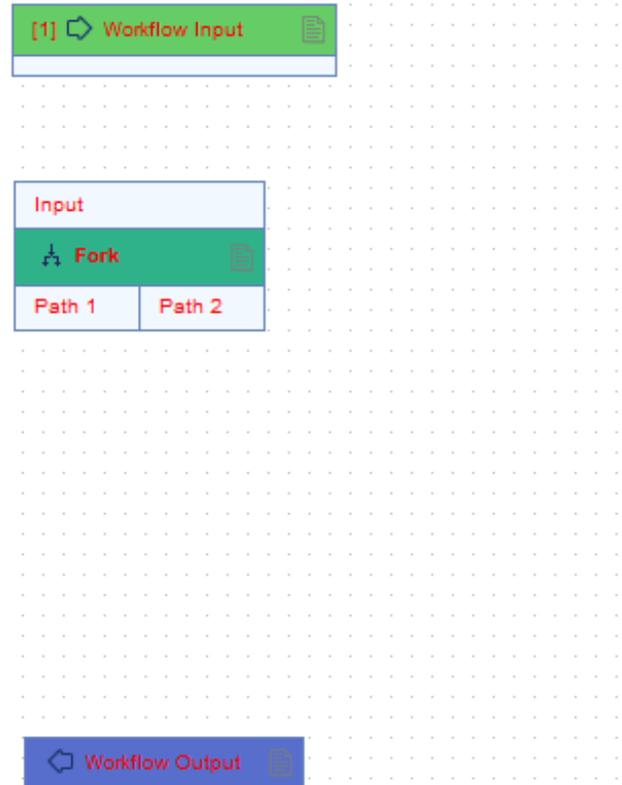


この後は、通常のRNA-seq解析と同様に、リファレンス配列や群間比較のパラメータを設定する

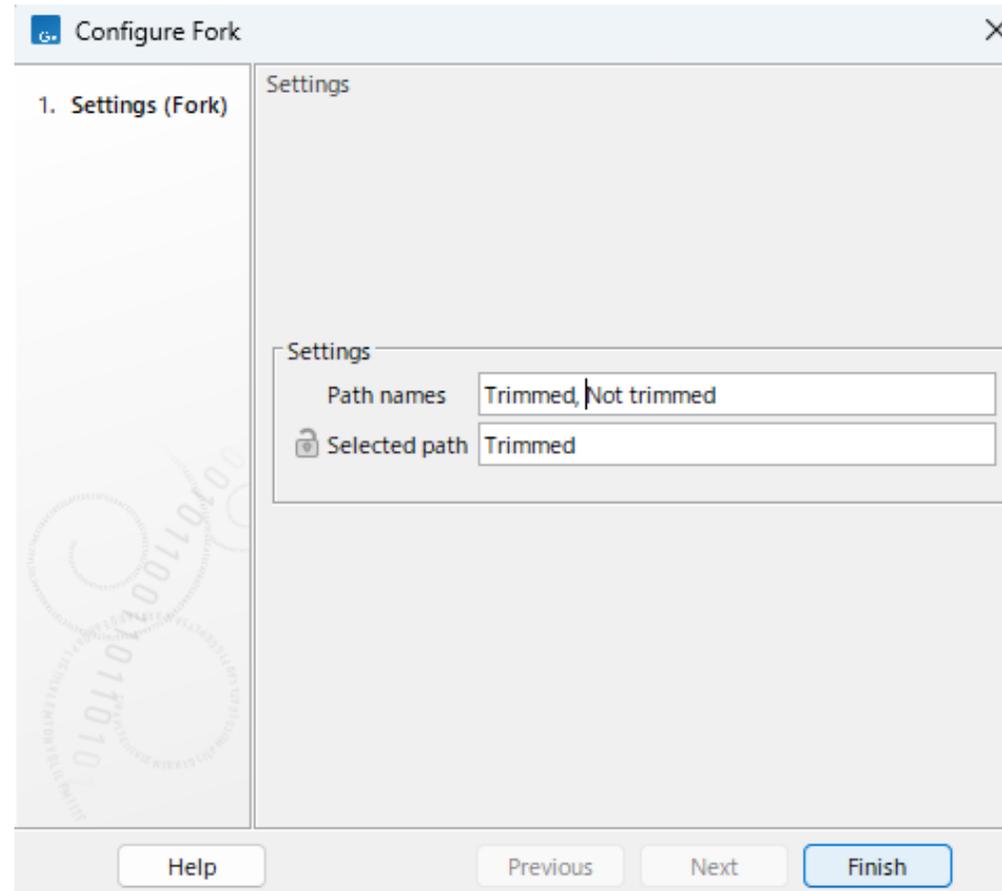
パターン3: 入力するデータの種類によって処理が異なる場合



パターン3: 入力するデータの種類によって処理が異なる場合

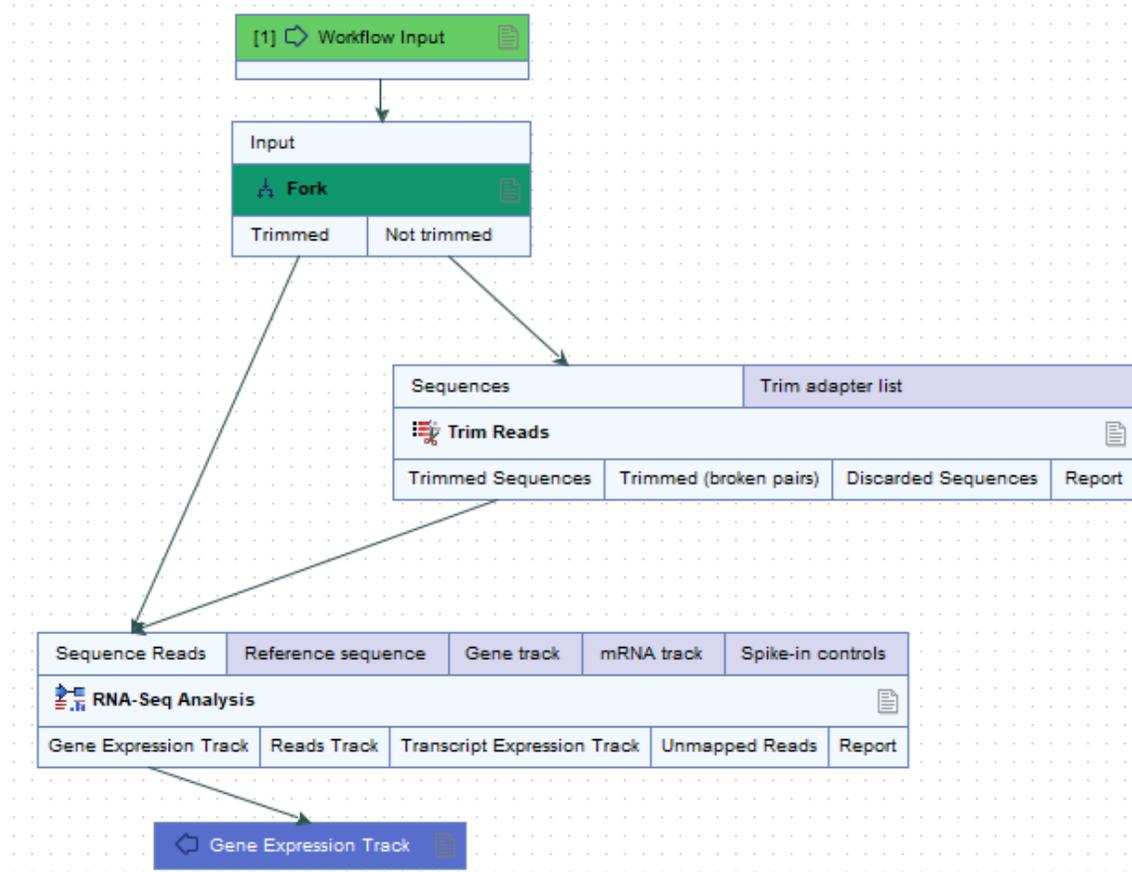


Input要素の下に“Fork”要素を配置

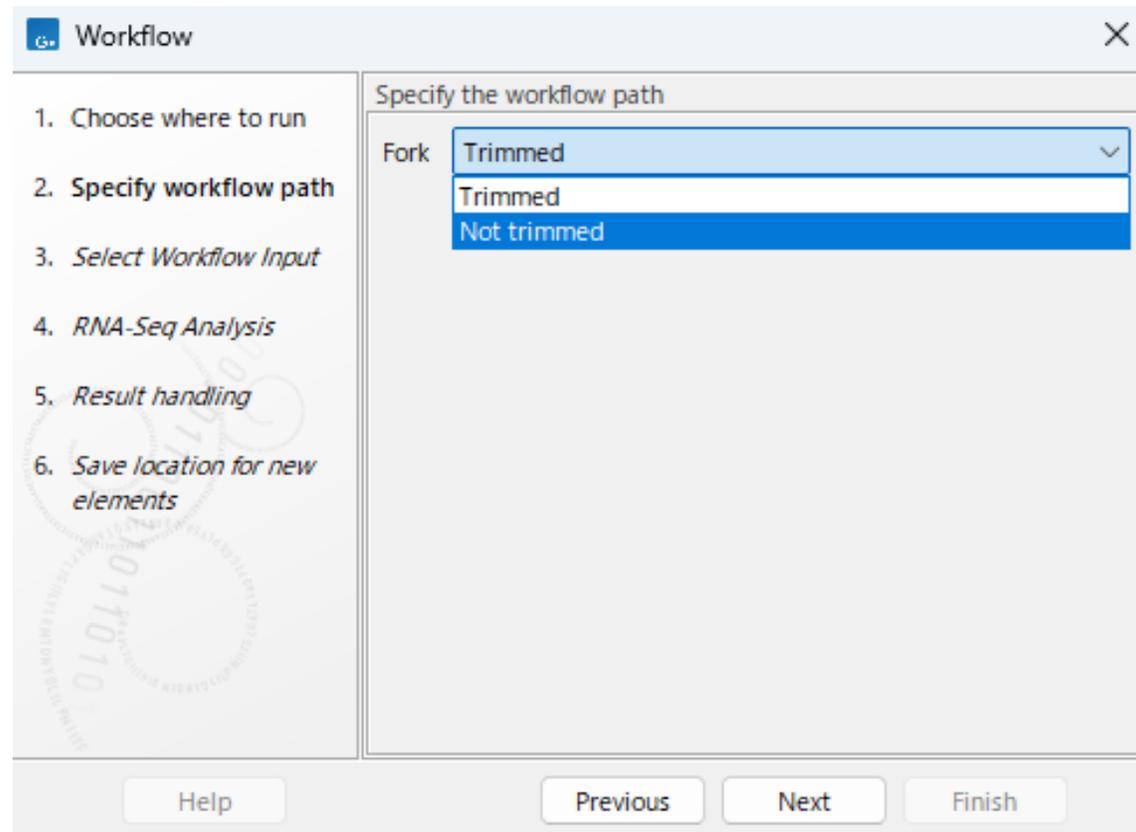


Fork要素をダブルクリックし、
分岐の名前（Path names）とデフォルトのルート（Selected path）を指定
3つ以上の分岐を作ることも可能

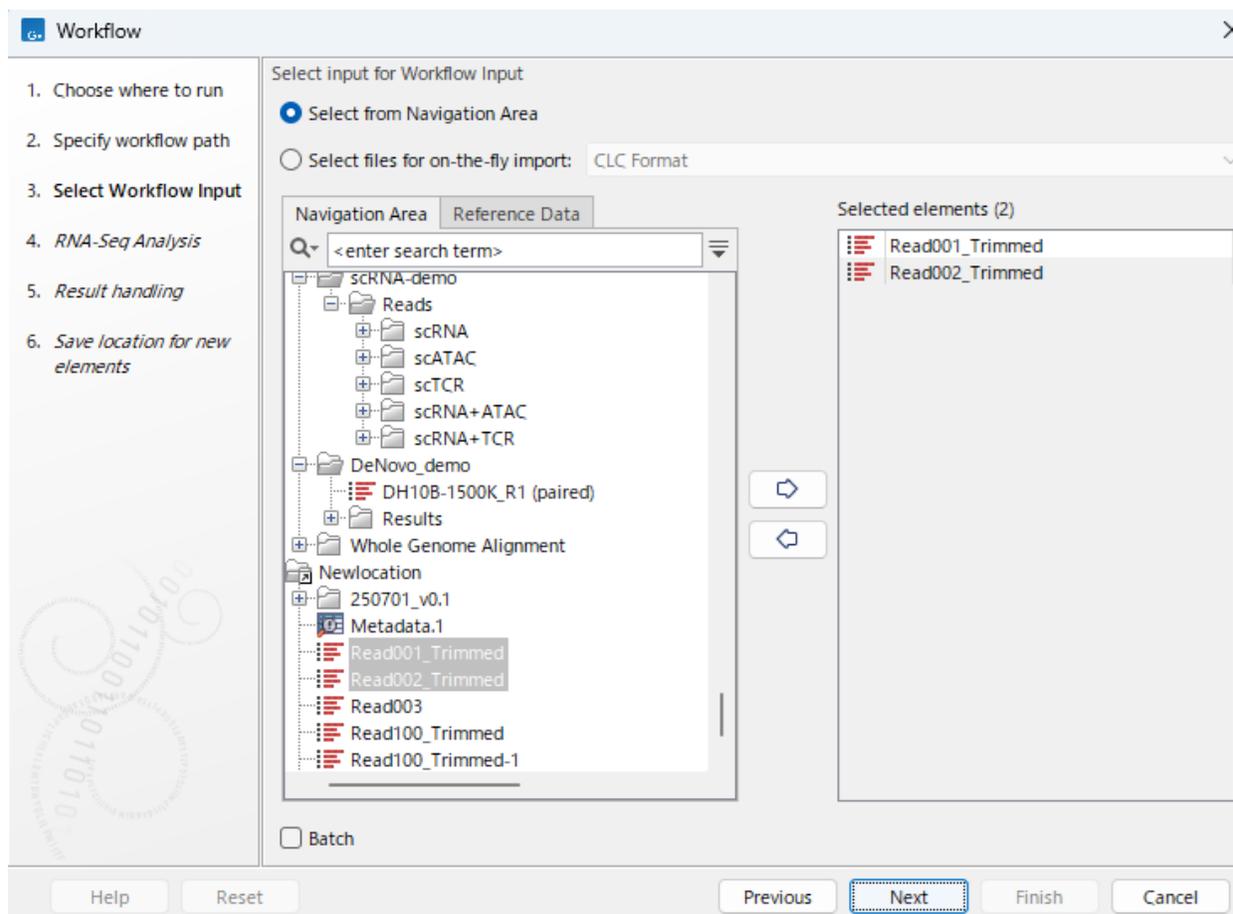
パターン3: 入力するデータの種類によって処理が異なる場合



それぞれの経路に応じたツールを配置する

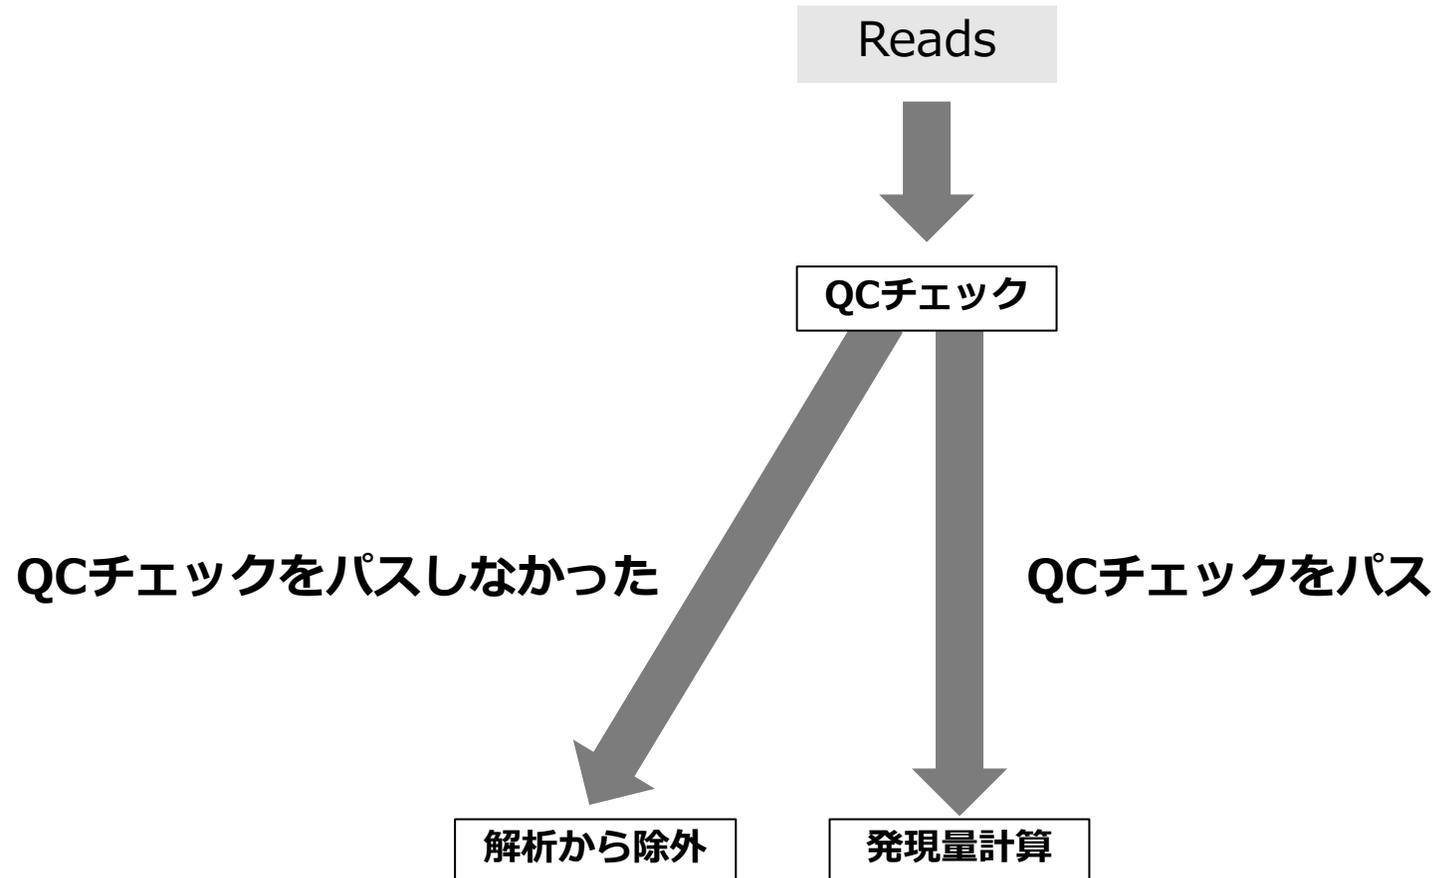


ワークフローを起動し、
はじめにどのルートを使うかを選択

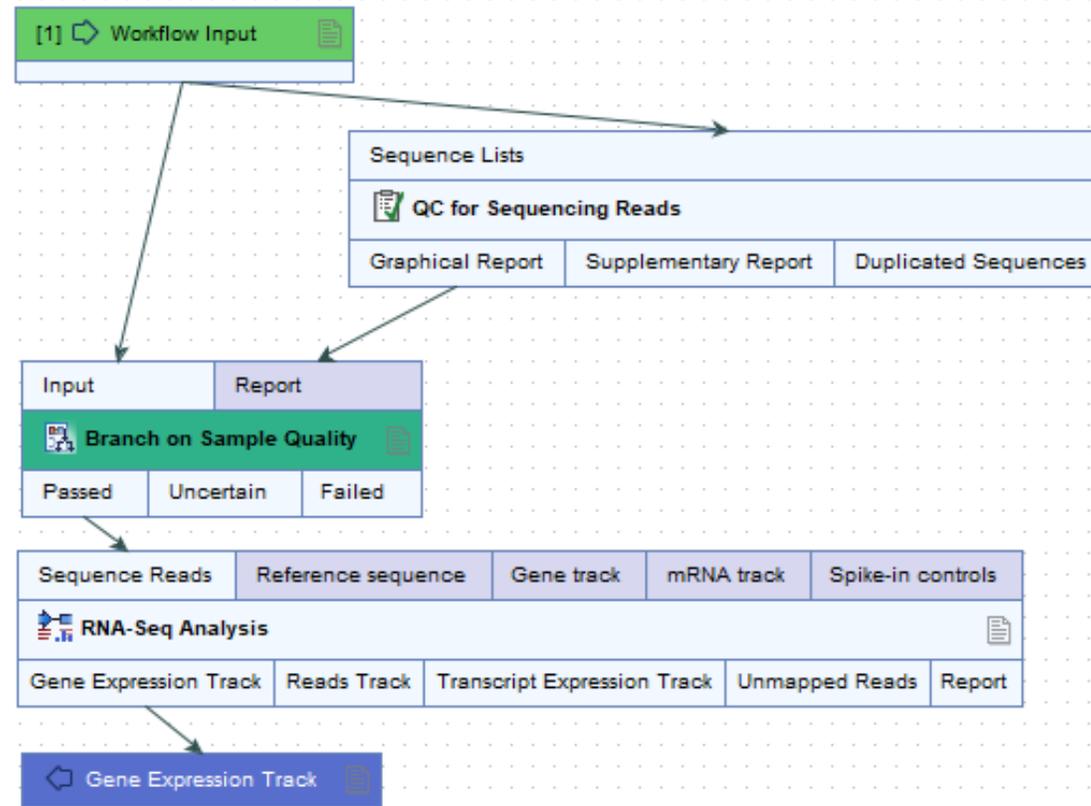


その後は、通常のワークフローと同じく、
入力データと各パラメータを指定する

パターン4: QCチェックの結果に応じて処理を変える



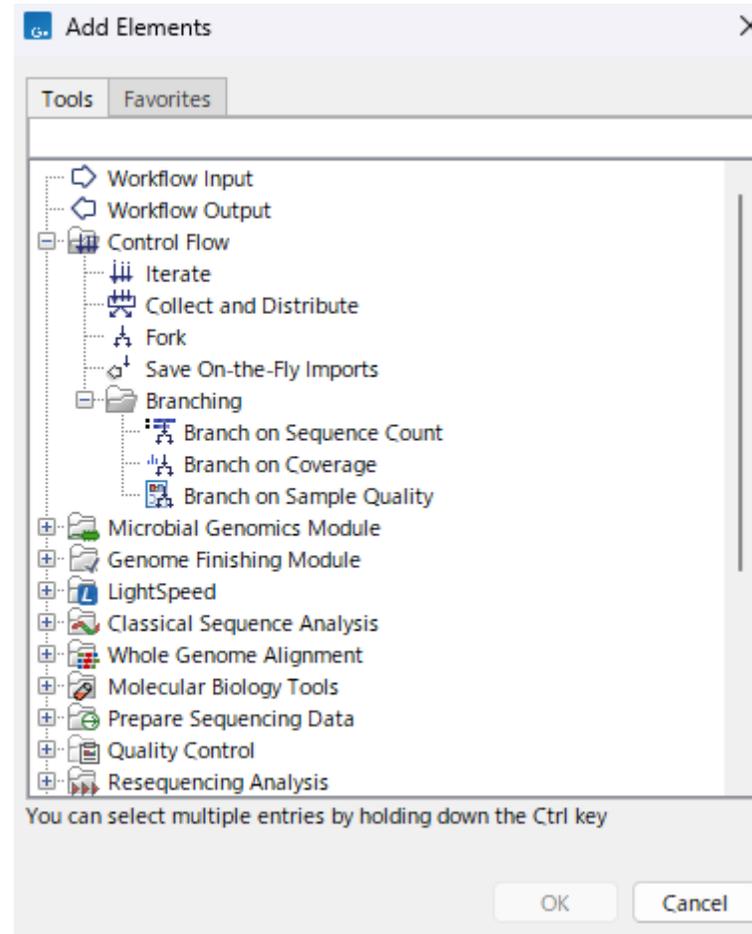
パターン4: QCチェックの結果に応じて処理を変える



“Branch on Sample Quality”要素を使用する

QCチェックでの分岐させるには、QCチェックのレポートが必要なので、QC for Sequencing Readsツールも追加し、その出力であるレポートも Branch on Sample Qualityへの入力とする必要がある

パターン4: QCチェックの結果に応じて処理を変える



その他に、カバレッジに応じて分岐（Branch on Coverage）や、リードの本数で分岐（Branch on Sequence Count）させる要素がある

お問い合わせ先：フィルジエン株式会社

TEL: 052-624-4388 (9:00～17 : 00)

FAX: 052-624-4389

E-mail: support@filgen.jp