

笔记 I: fastTopics 包

Jonathan Chow

2022-10-04

目录

| | |
|--------------------------------------|----|
| 1 Rcpp 包的一般结构 | 2 |
| 2 fastTopics 包 | 3 |
| 3 辅助函数 | 3 |
| 3.1 src 目录 | 3 |
| 3.2 verify_args.R 和 misc.R | 3 |
| 4 评价指标函数 | 5 |
| 5 模型拟合函数 | 8 |
| 5.1 pnmfem.R、ccd.R 和 scd.R | 8 |
| 5.2 poisson2multinom.R | 10 |
| 5.3 fit_poisson_nmf.R | 11 |
| 5.4 fit_topic_model.R | 21 |
| 6 绘图函数 | 23 |
| 6.1 structure_plot.R | 23 |

| | |
|---|----|
| 1 RCPP 包的一般结构 | 2 |
| 6.2 other_plots.R | 28 |
| 6.3 embedding_plots.R 和 volcano_plots.R | 30 |
| 7 数据模拟函数 | 30 |

1 Rcpp 包的一般结构

```

DemoRcpp
DESCRIPTION
NAMESPACE
R
  RcppExports.R
  Read-and-delete-me
man
  DemoRcpp-package.Rd
  rcpp_hello_world.Rd
src
  RcppExports.cpp
  rcpp_hello_world.cpp

```

R 目录下存放 R 代码，编写包函数。其中 RcppExports.R 存放调用 C++ 代码的 R 接口函数。

src 目录下存放 C++ 代码，编写库函数。其中 RcppExports.cpp 用于接收 R 的对象，并转化成 C++ 的对象。



2 fastTopics 包

fastTopics 包通过 R 实现使用期望极大算法（EM）和顺序坐标下降算法（CCD、SCD）拟合 Poisson 非负矩阵分解模型和多项主题模型。

模型拟合函数: `fit_multinom_model.R`, `fit_poisson_nmf.R`,
`fit_topic_model.R`。

评价指标函数: `likelihood.R`。

绘图函数: `structure_plot.R`, `other_plots.R`, `embedding_plots.R`,
`volcano_plots.R`。

数据模拟函数: `datasim.R`。

辅助函数: R 目录下的其他函数和 src 目录下的函数主要用于辅助上述主要函数。或者实现较为普遍的功能，或者加速核心算法。

3 辅助函数

3.1 src 目录

src 目录下的代码使用 C++ 编写，然后利用 Rcpp 实现与 R 的交互，以加速核心算法。

`poismix.cpp` 和 `pnmfem.cpp` 主要用于实现 EM 算法的核心参数迭代。`ccd.cpp` 主要用于实现 CCD 算法的核心参数迭代。`scd.cpp` 主要用于实现 SCD 算法的核心参数迭代。`cost.cpp` 主要用于计算评价指标，比如损失函数、一阶 KKT 条件。

主要使用矩阵库 `RcppArmadillo`。并使用 `RcppParallel` 进行并行运算。

3.2 verify_args.R 和 misc.R

`verify_args.R` 是验证输入合法性的文件。需要注意的是用 `deparse(substitute(x))` 来标记代码。实现的函数如下表。

| 参数 | 描述 |
|--|--|
| <code>verify.positive</code> | 验证 <code>x</code> 是具有正元素的向量。 |
| <code>vector</code> | |
| <code>verify.nonnegat</code> | 验证 <code>x</code> 是非负矩阵。 |
| <code>matrix</code> | |
| <code>verify.count.</code> | 验证 <code>x</code> 是有效的计数矩阵。 |
| <code>matrix</code> | |
| <code>verify.fit</code> | 验证 <code>x</code> 是有效的多项式主题模型拟合或 Poisson 非负矩阵分解。 |
| <code>verify.fit.and.count.matrix</code> | 验证 <code>x</code> 是有效的计数矩阵，且 <code>fit</code> 是有效的多项式主题模型拟合或 Poisson 非负矩阵分解。 |
| <code>is.scalar</code> | 验证 <code>x</code> 是没有缺失项的有限标量。 |

`misc.R` 是实现基本运算的文件。实现的函数如下表。需要使用 `Matrix`、`stats` 等软件包。

| 参数 | 描述 |
|------------------------------|---|
| <code>pfromz</code> | 根据 z-score 计算双尾 p 值。。 |
| <code>lpfromz</code> | 从 z-score 计算 log10 双尾 p 值。 |
| <code>is.sparse.</code> | 验证 <code>x</code> 是否为稀疏矩阵。 |
| <code>matrix</code> | |
| <code>get.nonzeros</code> | 从稀疏矩阵的第 <code>j</code> 列中高效提取非零元素。 |
| <code>any.allzero.</code> | 检查矩阵是否包含一个或多个全零列。 |
| <code>cols</code> | |
| <code>remove.allzero.</code> | 移除全零列。 |
| <code>cols</code> | |
| <code>apply.</code> | 对稀疏矩阵的所有非零项应用 <code>f</code> 算子。 |
| <code>nonzeros</code> | |
| <code>x_over_</code> | 当 <code>X</code> 是稀疏矩阵时高效计算 <code>X/(crossprod(A,B) + e)</code> 。使用了 Rcpp 代码。 |
| <code>tcrossprod</code> | |
| <code>repmat</code> | 利用 <code>rbind(x, ..., x)</code> 返回 m^*n 矩阵。 |
| <code>scale.cols</code> | 将 <code>A[,i]</code> 列用 <code>b[i]</code> 缩放。 |

| 参数 | 描述 |
|------------------------------|--|
| <code>normalize.rows</code> | 对 A 的每一行缩放使行和为 1。 |
| <code>normalize.cols</code> | 对 A 的每一列缩放使列和为 1。 |
| <code>normalize.rows.</code> | 对 A 的每一行缩放使每一行最大项为 1。 |
| <code>by.max</code> | |
| <code>le.diff</code> | 向量 x 的等长差分。 |
| <code>rescale.</code> | 重新缩放 F 和 L 使 F 的第 k 列和 L 的第 k 列均值相同。 |
| <code>factors</code> | |
| <code>rand</code> | 产生均匀分布的随机数。 |
| <code>initialize.</code> | 预先指定初始化 RcppParallel 的多线程数目。使用了 Rcpp 代码。 |
| <code>multithreading</code> | |
| <code>fit_pnmf_</code> | 处理秩为 1 的 Poisson NMF。 |
| <code>rank1</code> | |
| <code>hpds</code> | 计算最高后验密度 (HPD) 区间。 |
| <code>min_kl_</code> | 计算最小 KL 散度。 |
| <code>poisson</code> | |
| <code>le_lfc</code> | 计算“最小极限”LFC 统计 $LFC(j) = \log_2(f_j/f_k)$ 。 |

4 评价指标函数

`likelihood.R` 计算 Poisson NMF 模型与主题模型的评价指标。

输入参数表。

| 参数 | 描述 |
|------------------|---|
| <code>X</code> | $n*m$ 的非负矩阵。可以是稀疏矩阵 <code>dgCMatrix</code> 或稠密矩阵 <code>matrix</code> 。 |
| <code>fit</code> | Poisson NMF 或多项式主题模型的拟合。比如 <code>fit_poisson_nmf</code> 或 <code>fit_topic_model</code> 的输出。 |
| <code>A</code> | $n*k$ 维的 L 矩阵。是稠密矩阵。 |
| <code>B</code> | $k*m$ 维的 F 矩阵。是稠密矩阵。 |
| <code>e</code> | 为避免计算零的对数而添加的小正常数。代价是产生小的不精确。 |

| 参数 | 描述 |
|---------|--|
| family | 模型选择。实现了两种模型: <code>poisson</code> 计算 Poisson NMF 的相应的值, <code>multinom</code> 计算多项式主题模型的相应的值。 |
| version | 计算引擎。实现了两种选择: R 表示全部在 R 中计算, 对于 X 稠密矩阵计算速度快; Rcpp 表示使用了 Rcpp 进行计算, 对于 X 大且稀疏矩阵计算速度快且内存占用小。未指定此选项时, 根据 X 的类型调用最优的选项 |

实现的主要函数如下。

```
loglik_poisson_nmf <- function (X, fit, e = 1e-8)
  loglik_helper(X, fit, "loglik.poisson", e)

loglik_multinom_topic_model <- function (X, fit, e = 1e-8)
  loglik_helper(X, fit, "loglik.multinom", e)

deviance_poisson_nmf <- function (X, fit, e = 1e-8)
  loglik_helper(X, fit, "deviance.poisson", e)
```

Poisson 非负矩阵分解模型: 计数矩阵 $X \in \mathbb{R}^{n \times m}$, 非负矩阵参数 $L \in \mathbb{R}_+^{n \times K}$, $F \in \mathbb{R}_+^{m \times K}$, 对 $K \geq 1$, 满足

$$x_{ij}|L, F \sim Poisson(\lambda_{ij})$$

$$\lambda_{ij} = (LF^T)_{ij} = \sum_{k=1}^K l_{ik} f_{jk}$$

多项生成模型: 计数矩阵 $X \in \mathbb{R}^{n \times m}$, 非负矩阵参数 $L^* \in \mathbb{R}_+^{n \times K}$, $F^* \in \mathbb{R}_+^{m \times K}$, 其中 l_{ik}^* , f_{jk}^* 要求和一性, 即

$$\sum_{k=1}^K l_{ik}^* = 1, \sum_{j=1}^m f_{jk}^* = 1$$

对 $K \geq 2$, 满足

$$x_{i1}, \dots, x_{im} \sim Mult\left(\sum_{j=1}^m x_{ij}; \pi_{i1}, \dots, \pi_{im}\right)$$

$$\pi_{ij} = (L^*(F^*)^T)_{ij} = \sum_{k=1}^K l_{ik}^* f_{jk}^*$$

构造映射 $\phi : L, F \rightarrow L^*, F^*$

$$u_k \leftarrow \sum_{j=1}^m f_{jk}, \forall k; \quad f_{jk}^* \leftarrow \frac{f_{jk}}{u_k}, \forall j, k$$

$$s_i \leftarrow \sum_{k=1}^K l_{ik} u_k, \forall i; \quad l_{ik}^* \leftarrow \frac{l_{ik} u_k}{s_i}, \forall i, k$$

注意到

$$\mathcal{L}_{Poisson}(X|L, F) = \prod_{i,j} \frac{\lambda_{ij}^{x_{ij}}}{x_{ij}!} e^{-\lambda_{ij}}, \quad \lambda_{ij} = \sum_k l_{ik} f_{jk}$$

$$\mathcal{L}_{Topic}(X|L^*, F^*) = \prod_i \frac{t_i!}{\prod_j x_{ij}!} \prod_j \pi_{ij}^{x_{ij}}, \quad \pi_{ij} = \sum_k l_{ik}^* f_{jk}^*, \quad t_i = \sum_j x_{ij}$$

又由于

$$\begin{aligned} \prod_{j=1}^m Poisson(x_j : \lambda_j) &= Mult(x_1, \dots, x_m : \sum_{j=1}^m x_{ij}; \frac{\lambda_1}{\sum_{j=1}^m \lambda_j}, \dots, \frac{\lambda_m}{\sum_{j=1}^m \lambda_j}) \\ &\times Poisson(\sum_{j=1}^m x_{ij} : \sum_{j=1}^m \lambda_j) \end{aligned}$$

于是

$$\mathcal{L}_{Poisson}(X|L, F) = \mathcal{L}_{Topic}(X|L, F) \prod_i Poisson(t_i : s_i)$$

于是 Poisson NMF 问题相当于求解

$$\underset{L, F}{argmax} \quad \mathcal{L}(X|L, F) = x_{ij} \log(l_i^T f_j) - \sum_{i,j} l_i^T f_j$$

$$s.t. \quad L \geq 0, F \geq 0$$

为了实现函数 `loglik_helper`, 我们需要以下辅助函数, 列表如下。需要使用软件包 `Matrix`、`stats`。

| 函数 | 描述 |
|---|--------------------------------|
| <code>loglik_poisson_const</code> | 计算 Poisson 对数似然中的常数项。 |
| <code>loglik_multinom_const</code> | 计算多项对数似然中的常数项。 |
| <code>deviance_poisson_const</code> | 计算 Poisson 偏差中的常数项。 |
| <code>poisson_nmf_kkt</code> | 计算 Poisson NMF 最优解处的一阶 KKT 残差。 |
| <code>loglik_size_factors</code> 和 <code>ldpois</code> | 尺寸指标。 |

函数 `loglik_helper`【核心代码】

```
if (output.type == "loglik.poisson" | output.type == "loglik.multinom") {
  f <- loglik_poisson_const(X) - cost(X,L,t(F),e,"poisson")
  if (output.type == "loglik.multinom")
    f <- f - loglik_size_factors(X,fit$F,fit$L)
} else if (output.type == "deviance.poisson")
  f <- deviance_poisson_const(X) + 2*cost(X,L,t(F),e,"poisson")
```

`cost()` 是在迭代过程中作为收敛指标的函数，主要部分调用了 C++ 代码。

5 模型拟合函数

5.1 pnmfem.R、ccd.R 和 scd.R

`pnmfem.R` 是利用 C++ 函数，利用 EM 更新 Poisson 回归模型的参数。

```
pnmfem_update_factors <- function (X, F, L, j = seq(1,ncol(X)),
                                     numiter = 1, nc = 1) {
  F <- t(F)
  if (nc == 1) {
```

```

if (is.matrix(X))
  F <- pnmfem_update_factors_rcpp(X,F,L,j-1,numiter)
else if (is.sparse.matrix(X))
  F <- pnmfem_update_factors_sparse_rcpp(X,F,L,j-1,numiter)
} else if (nc > 1) {
  if (is.matrix(X))
    F <- pnmfem_update_factors_parallel_rcpp(X,F,L,j-1,numiter)
  else if (is.sparse.matrix(X))
    F <- pnmfem_update_factors_sparse_parallel_rcpp(X,F,L,j-1,numiter)
}
return(t(F))
}

pnmfem_update_loadings <- function (X, F, L, i = seq(1,nrow(X)),
                                      numiter = 1, nc = 1) {
  X <- t(X)
  L <- t(L)
  if (nc == 1) {
    if (is.matrix(X))
      L <- pnmfem_update_factors_rcpp(X,L,F,i-1,numiter)
    else if (is.sparse.matrix(X))
      L <- pnmfem_update_factors_sparse_rcpp(X,L,F,i-1,numiter)
  } else if (nc > 1) {
    if (is.matrix(X))
      L <- pnmfem_update_factors_parallel_rcpp(X,L,F,i-1,numiter)
    else if (is.sparse.matrix(X))
      L <- pnmfem_update_factors_sparse_parallel_rcpp(X,L,F,i-1,numiter)
  }
  return(t(L))
}

```

`ccd.R` 是利用 C++ 函数，利用 CCD 更新 Poisson 回归模型的参数。

`scd.R` 是利用 C++ 函数，利用 SCD 更新 Poisson 回归模型的参数。

5.2 poisson2multinom.R

利用 Poisson NMF 和多项主题模型之间的关系，从 Poisson NMF 拟合中恢复多项式主题模型拟合。

输入参数是类 `poisson_nmf_fit` 的对象，比如 `init_poisson_nmf` 或 `fit_poisson_nmf` 的输出。输出是类 `multinom_topic_model_fit` 的对象。

实现的主要函数是 `poisson2multinom`。

```
poisson2multinom <- function (fit) {

  if (inherits(fit, "multinom_topic_model_fit"))
    return(fit)
  if (!inherits(fit, "poisson_nmf_fit"))
    stop("Input argument \"fit\" should be an object of class ",
         "\"poisson_nmf_fit\"")
  verify.fit(fit)
  if (ncol(fit$F) < 2 | ncol(fit$L) < 2)
    stop("Input matrices \"fit$F\" and \"fit$L\" should have 2 or more",
         "columns")

  out <- get_multinom_from_pnmf(fit$F, fit$L)
  fit$F <- out$F
  fit$L <- out$L
  fit$s <- out$s

  class(fit) <- c("multinom_topic_model_fit", "list")
  return(fit)
}
```

为了实现函数 `poisson2multinom`, 我们需要辅助函数 `get_multinom_from_pnmf`。

```
get_multinom_from_pnmf <- function (F, L) {
  u <- colSums(F)
  F <- scale.cols(F, 1/u)
```

```

L <- scale.cols(L,u)
s <- rowSums(L)
L <- L / s
return(list(F = F,L = L,s = s))
}

```

5.3 fit_poisson_nmf.R

Poisson NMF 问题：计数矩阵 $X \in \mathbb{R}^{n \times m}$ ，非负矩阵参数 $L \in \mathbb{R}_+^{n \times K}$, $F \in \mathbb{R}_+^{m \times K}$, 对 $K \geq 1$, 满足

$$x_{ij}|L, F \sim Poisson(\lambda_{ij}),$$

$$\lambda_{ij} = (LF^T)_{ij} = \sum_{k=1}^K l_{ik} f_{jk},$$

并分别使用 EM、CCD、SCD 解决该问题。

使用三种方式来衡量模型的进展：对数似然（或偏差）的改进、模型参数的变化、KKT 系统的残差。当迭代接近损失函数的（局部）稳定点时，模型参数应当趋于不变、KKT 系统的残差应当消失。使用 `plot_progress` 查看模型进程。

输入参数表。

| 参数 | 描述 |
|----------------------|--|
| <code>X</code> | <code>n*m</code> 的非负矩阵。可以是稀疏矩阵 <code>dgCMatrix</code> 或稠密矩阵 <code>matrix</code> , 但有一些例外。 |
| <code>k</code> | 矩阵的秩。是预先设定的大于等于 2 的整数。设定初始值 (<code>fit0</code> 或 <code>F</code> 、 <code>L</code>) 时忽略此选项。 |
| <code>fit0</code> | 初始模型拟合。是类 <code>poisson_nmf_fit</code> 的对象, 比如 <code>init_poisson_nmf</code> 或 <code>fit_poisson_nmf</code> 的输出。 |
| <code>numiter</code> | 迭代次数。是 <code>F</code> 和 <code>L</code> 的更新次数。 |
| <code>update</code> | 更新特定的 <code>F</code> 行。默认更新所有的 <code>F</code> 行。此选项只针对方法 <code>em</code> <code>factors</code> 和 <code>scd</code> 。 |

| 参数 | 描述 |
|----------------------|--|
| <code>update</code> | . 更新特定的 L 行。默认更新所有的 L 行。此选项只针对方法 <code>em</code> 、 <code>loadings</code> 和 <code>scd</code> 。 |
| <code>method</code> | 更新方法。实现了四种方法：乘法更新 <code>mu</code> ，期望最大化 <code>em</code> ，顺序坐标下降 <code>scd</code> ，循环坐标下降 <code>ccd</code> 。 |
| <code>init</code> | . 初始化 F 和 L 的方法。实现了两种方法： <code>random</code> 表示均匀随机 |
| <code>method</code> | 初始化 F 和 L， <code>topicscore</code> 表示使用（非常快的）Topic SCORE 算法初始化 F、通过运行少量 SCD 初始化 L。设定初始值（ <code>fit0</code> 或 F、L）时忽略此选项。 |
| <code>control</code> | 控制算法的参数列表。用于控制优化算法和 Topic SCORE 算法（若选择 <code>topicscore</code> ）。详见 <code>control</code> 表。 |
| <code>verbose</code> | 进度信息控件。实现了三个选项： <code>detail</code> 表示打印每次迭代的信息， <code>progressbar</code> 表示使用进度条显示算法进程， <code>none</code> 表示不显示进度信息。 |

`control` 表。

| 参数 | 描述 |
|----------------------|--|
| <code>numiter</code> | 内部循环的迭代次数。此选项在方法 <code>mu</code> 和 <code>ccd</code> 下必须设置为 1。 |
| <code>nc</code> | 用于更新的 RcppParallel 线程数。 <code>nc</code> 为 NA 时线程数调用 RcppParallel 的 <code>defaultNumThreads</code> 。此选项忽略乘法更新 <code>mu</code> 。 |
| <code>minval</code> | 用来保护乘法更新的小正常数。具体代码为 <code>F <- pmax(F1,minval)</code> 和 <code>L <- pmax(L1,minval)</code> 。允许设置 <code>minval = 0</code> 此时将给出一个警告。 |
| <code>eps</code> | 为避免计算零的对数而添加的小正常数。增大此选项的值会加快收敛速度但也会影响优化的精度。 |
| <code>zero.</code> | 判定是否为 0 的小正常数。将小于或等于阈值 <code>zero.threshold</code> 的项判定为 0。 |

`init_poisson_nmf` 和 `fit_poisson_nmf` 返回值表。

| 参数 | 描述 |
|----------|---|
| F | F 的最佳估计值。 |
| L | L 的最佳估计值。 |
| loss | 最佳估计值处的损失函数值。 |
| iter | 已完成的迭代数量。 |
| progress | 算法进度详细信息的数据表。数据表有 <code>numiter</code> 行。数据表的列详见 <code>progress</code> 表。 |

progress 表。

| 参数 | 描述 |
|-------------------------|-----------------------------|
| <code>iter</code> | 迭代次数 |
| <code>loglik</code> | 当前最佳点的 Poisson NMF 模型的对数似然。 |
| <code>loglik.</code> | 当前最佳点的多项式主题模型的对数似然。 |
| <code>multinom</code> | |
| <code>dev</code> | 当前最佳点的偏差。 |
| <code>res</code> | 当前最佳点的 KKT 一阶最优条件的残差。 |
| <code>delta.f</code> | F 的最大变化。 |
| <code>delta.l</code> | L 的最大变化。 |
| <code>nonzeros.f</code> | F 中非零元素所占的比例。 |
| <code>nonzeros.l</code> | L 中非零元素所占的比例。 |
| <code>timing</code> | 以秒为单位的运行时间。 |

实现的主要函数是 `fit_poisson_nmf`。

首先，输入相应参数。

```
    init.method = c("topicscore", "random"),
    control = list(),
    verbose = c("progressbar", "detailed", "none")) {
```

其次，数据检查与预处理。

再次，初始化估计值。

```
fit <- rescale.fit(fit)
fit <- safeguard.fit(fit, control$minval)
```

最后，更新参数值。

```
if (verbose == "detailed")
  cat("iter loglik(PoisNMF) loglik(multinom) res(KKT) |F-F'| |L-L'|",
      "nz(F) nz(L) beta\n")
fit <- fit_poisson_nmf_main_loop(X, fit, numiter, update.factors,
                                   update.loadings, method, control,
                                   verbose)

# Output the updated "fit".
fit$progress <- rbind(fit0$progress, fit$progress)
dimnames(fit$F) <- dimnames(fit0$F)
dimnames(fit$L) <- dimnames(fit0$L)
dimnames(fit$Fn) <- dimnames(fit0$Fn)
dimnames(fit$Ln) <- dimnames(fit0$Ln)
dimnames(fit$Fy) <- dimnames(fit0$Fy)
dimnames(fit$Ly) <- dimnames(fit0$Ly)
class(fit) <- c("poisson_nmf_fit", "list")
return(fit)
}
```

为了实现函数 `fit_poisson_nmf_main_loop`, 我们需要以下辅助函数, 列表如下。

| 函数 | 描述 |
|------------------|------------------|
| update_ | F 和 L 的单次更新。 |
| poisson_nmf | |
| update_factors | F 的单次更新。 |
| _poisson_nmf | |
| update_loadings | L 的单次更新。 |
| _poisson_nmf | |
| rescale.fit | 重新调整当前最佳的 F 和 L。 |
| safeguard.fit | 强制使 F 和 L 是正的。 |
| fit_poisson_nmf | control 的默认值。 |
| _control_default | |

具体代码如下。

函数 *update_poisson_nmf*

```
update_poisson_nmf <- function (X, fit, update.factors, update.loadings,
                                 method, control) {

  # Compute L.
  if (length(update.loadings) > 0) {
    fit$L <- update_loadings_poisson_nmf(X, fit$F, fit$L, update.loadings,
                                            method, control)
    fit$L <- pmax(fit$L, control$minval)
  }

  # Compute F.
  if (length(update.factors) > 0) {
    fit$F <- update_factors_poisson_nmf(X, fit$F, fit$L, update.factors,
                                           method, control)
    fit$F <- pmax(fit$F, control$minval)
  }
}
```

```

# fit$Fy <- fit$F
# fit$Ly <- fit$L
# fit$Fn <- fit$F
# fit$Ln <- fit$L

fit <- rescale.fit(fit)

# Compute loss.
fit$loss <- sum(cost(X,fit$L,t(fit$F),control$eps))
# fit$loss.fonly <- fit$loss

return(fit)
}

```

函数 *update_factors_poisson_nmf*

```

update_factors_poisson_nmf <- function (X, F, L, j, method, control) {
  numiter <- control$numiter
  nc      <- control$nc
  eps     <- control$eps
  if (method == "mu")
    F <- t(betanmf_update_factors(X,L,t(F)))
  else if (method == "em")
    F <- pnmfem_update_factors(X,F,L,j,numiter,nc)
  else if (method == "ccd")
    F <- t(ccd_update_factors(X,L,t(F),nc,eps))
  else if (method == "scd")
    F <- t(scd_update_factors(X,L,t(F),j,numiter,nc,eps))
  return(F)
}

```

函数 *update_loadings_poisson_nmf*

```
update_loadings_poisson_nmf <- function (X, F, L, i, method, control) {
  numiter <- control$numiter
  nc       <- control$nc
  eps      <- control$eps
  if (method == "mu")
    L <- betanmf_update_loadings(X,L,t(F))
  else if (method == "em")
    L <- pnmfem_update_loadings(X,F,L,i,numiter,nc)
  else if (method == "ccd")
    L <- ccd_update_loadings(X,L,t(F),nc,eps)
  else if (method == "scd")
    L <- scd_update_loadings(X,L,t(F),i,numiter,nc,eps)
  return(L)
}
```

函数 *rescale.fit*

```
rescale.fit <- function (fit) {

  # Rescale the "current best" factors and loadings.
  out     <- rescale.factors(fit$F,fit$L)
  fit$F   <- out$F
  fit$L   <- out$L

  # # Rescale the non-extrapolated factors and loadings.
  # out     <- rescale.factors(fit$Fn,fit$Ln)
  # fit$Fn <- out$F
  # fit$Ln <- out$L
  #

  # # Rescale the extrapolated factors and loadings.
  # out     <- rescale.factors(fit$Fy,fit$Ly)
  # fit$Fy <- out$F
  # fit$Ly <- out$L
}
```

```

    return(fit)
}

```

函数 *safeguard.fit*

```

safeguard.fit <- function (fit, minval) {
  fit$F <- pmax(fit$F,minval)
  fit$L <- pmax(fit$L,minval)
  fit$Fn <- pmax(fit$Fn,minval)
  fit$Ln <- pmax(fit$Ln,minval)
  fit$Fy <- pmax(fit$Fy,minval)
  fit$Ly <- pmax(fit$Ly,minval)
  return(fit)
}

```

函数 *fit_poisson_nmf_control_default*

```

fit_poisson_nmf_control_default <- function()
  list(numiter      = 4,
       init.numiter   = 10,
       minval        = 1e-10,
       eps           = 1e-8,
       zero.threshold = 1e-6,
       nc            = 1,
       extrapolate    = FALSE,
       extrapolate.reset = 20,
       beta.increase   = 1.1,
       beta.reduce     = 0.75,
       betamax.increase = 1.05)

```

函数 *fit_poisson_nmf_main_loop*【核心代码】


```

# Perform a basic coordinate-wise update of the factors and loadings.
extrapolate <- FALSE
fit <- update_poisson_nmf(X, fit, update.factors, update.loadings,
                           method, control)
}

t2 <- proc.time()

# Update the iteration number.
fit$iter <- fit$iter + 1

# Update the "progress" data frame.
progress[i, "iter"] <- fit$iter
progress[i, "loglik"] <- loglik.const - fit$loss
progress[i, "loglik.multinom"] <-
  loglik.const - fit$loss - sum(loglik_size_factors(X, fit$F, fit$L))
progress[i, "dev"] <- dev.const + 2*fit$loss
progress[i, "res"] <- with(poisson_nmf_kkt(X, fit$F, fit$L),
                           max(abs(rbind(F[update.factors, ],
                                         L[update.loadings,])))))
progress[i, "delta.f"] <- max(abs(fit$F - fit0$F))
progress[i, "delta.l"] <- max(abs(fit$L - fit0$L))
progress[i, "beta"] <- fit$beta
progress[i, "betamax"] <- fit$betamax
progress[i, "timing"] <- t2["elapsed"] - t1["elapsed"]
progress[i, "nonzeros.f"] <- mean(fit$F > control$zero.threshold)
progress[i, "nonzeros.l"] <- mean(fit$L > control$zero.threshold)
progress[i, "extrapolate"] <- extrapolate
if (verbose == "detailed")
  cat(sprintf("%4d %+0.8e %+0.9e %0.2e %0.1e %0.1e %0.3f %0.3f %0.2f\n",
              fit$iter, progress[i, "loglik"], progress[i, "loglik.multinom"],
              progress[i, "res"], progress[i, "delta.f"],
              progress[i, "delta.l"], progress[i, "nonzeros.f"],
              progress[i, "nonzeros.l"], extrapolate * progress[i, "beta"]))

```

```

}

# Output the updated "fit".
fit$progress <- progress
return(fit)
}

```

5.4 fit_topic_model.R

适合大或者复杂的数据集。

模型拟合为分四个步骤完成：使用型 `init_poisson_nmf` 初始化 Poisson NMF 模型，使用 `fit_poisson_nmf` 运行 100 次 EM 更新，使用 `fit_poisson_nmf` 运行运行 100 次外推 SCD 更新，使用 `poisson2multinom` 恢复多项式主题模型。

EM 能快速到达最优值附近，SCD 能快速收敛到最优值。对于较大的数据集可能需要更多次 EM 迭代。

输入参数表。

| 参数 | 描述 |
|-----------------------------|---|
| <code>X</code> | <code>n*m</code> 的非负矩阵。可以是稀疏矩阵 <code>dgCMatrix</code> 或稠密矩阵 <code>matrix</code> 。 |
| <code>k</code> | 矩阵的秩。是预先设定的大于等于 2 的整数。 |
| <code>numiter.main</code> | 主要步骤迭代次数。 |
| <code>numiter.refine</code> | 细化步骤迭代次数。 |
| <code>method.main</code> | 主要步骤更新方法。 |
| <code>method.refine</code> | 细化步骤更新方法。 |
| <code>init.method</code> | 初始化 F 和 L 的方法。 |
| <code>control.init</code> | 控制初始化算法的参数列表。 |
| <code>control.main</code> | 控制主要步骤算法的参数列表。 |
| <code>control.refine</code> | 控制细化步骤算法的参数列表。 |
| <code>verbose</code> | 进度信息控件。 |

输出是由函数 `poisson2multinom` 生成的多项主题模型的拟合。

```
fit_topic_model <-
  function (X, k, numiter.main = 100, numiter.refine = 100, method.main = "em",
           method.refine = "scd", init.method = c("topicscore", "random"),
           control.init = list(), control.main = list(numiter = 4),
           control.refine = list(numiter = 4, extrapolate = TRUE),
           verbose = c("progressbar", "detailed", "none")) {

  # Check the input data matrix.
  verify.count.matrix(X)

  # Check and process input argument "verbose".
  verbose <- match.arg(verbose)

  # If necessary, remove all-zero columns from the counts matrix.
  if (any.allzero.cols(X)) {
    X <- remove.allzero.cols(X)
    warning(sprintf(paste("One or more columns of X are all zero; after",
                          "removing all-zero columns, %d columns will be",
                          "used for model fitting"), ncol(X)))
  }

  # Initialize the Poisson NMF model fit.
  fit <- init_poisson_nmf(X, k = k, init.method = init.method,
                           control = control.init,
                           verbose = ifelse(verbose == "none",
                                           "none", "detailed"))

  # Perform the main model fitting step.
  fit <- fit_poisson_nmf(X, fit0 = fit, numiter = numiter.main,
                         method = method.main, control = control.main,
                         verbose = verbose)
```

```

# Perform the model refinement step.
if (numiter.refine > 0) {
  if (verbose != "none")
    cat("Refining model fit.\n")
  fit <- fit_poisson_nmf(X, fit0 = fit, numiter = numiter.refine,
                         method = method.refine, control = control.refine,
                         verbose = verbose)
}

# Output the multinomial topic model fit.
return(poisson2multinom(fit))
}

```

6 绘图函数

6.1 structure_plot.R

绘制结构图。

输入参数表。

| 参数 | 描述 |
|----------|---|
| fit | poisson_nmf_fit 或 multinom_topic_model_fit 类的对象。 若提供前者，则利用 poisson2multinom 恢复为后者。 |
| topics | 从上到下的主题排序。若不特别指定，默认最大的主题在最底下。 |
| grouping | 可选的分类变量。对样本行进行分组。 |
| loadings | 加载矩阵 L 的行顺序。 |
| order | |
| n | 最大样本数。 |
| colors | 结构图中用于绘制主题的颜色。 |
| gap | 组之间的水平间距。默认无间距。 |
| embed_ | 用于计算一维嵌入的函数。 |
| method | |

| 参数 | 描述 |
|---------|------------|
| ggplot_ | 用于创建图形的函数。 |
| call | |

实现的主要函数如下。

```
plot.poisson_nmf_fit <- function (x, ...)
  structure_plot(x,...)

plot.multinom_topic_model_fit <- function (x, ...)
  structure_plot(x,...)
```

为了实现函数 `structure_plot`, 我们需要以下辅助函数, 列表如下。

| 函数 | 描述 |
|-------------------------------------|-------------------------------------|
| structure_plot_default_embed_method | 默认方法。 |
| structure_plot_ggplot_call | 绘制图像。 |
| compile_structure_plot_data | 创建适合 <code>ggplot</code> 的数据表。 |
| compile_grouped_structure_plot_data | 分组情况下创建适合 <code>ggplot</code> 的数据表。 |

我们逐个分析。

函数 `structure_plot_default_embed_method`

```
structure_plot_default_embed_method <- function (fit,...) {
  if (nrow(fit$L) < 20)
    return(rnorm(nrow(fit$L)))
  else {
    d <- dim(fit$L)
    message(sprintf("Running tsne on %s x %s matrix.",d[1],d[2]))
    return(drop(suppressMessages(tsne_from_topics(fit,dims = 1,...))))
  }
}
```

函数 `structure_plot_ggplot_call`

需要载入包 `ggplot2`。

输入参数表。

| 函数 | 描述 |
|------------------------|--|
| <code>dat</code> | <code>ggplot</code> 所要求的数据表。至少包括三列： <code>sample</code> 包含样本（ <code>L</code> 矩阵的行）在水平轴上的位置， <code>topic</code> 包含一个主题（ <code>L</code> 的一列）， <code>prop</code> 包含每个样本的主题比例。 |
| <code>ticks</code> | 沿水平轴放置的组标签名称。若数据未进行分组则为 <code>NULL</code> 。 |
| <code>font.size</code> | 图中使用的字体大小。 |

```
structure_plot_ggplot_call <- function (dat, colors, ticks = NULL,
                                         font.size = 9)
  ggplot(dat, aes_string(x = "sample", y = "prop", color = "topic",
                         fill = "topic")) +
    geom_col() +
    scale_x_continuous(limits = c(0, max(dat$sample) + 1), breaks = ticks,
                       labels = names(ticks)) +
    scale_color_manual(values = colors) +
    scale_fill_manual(values = colors) +
    labs(x = "", y = "topic proportion") +
    theme_cowplot(font.size) +
    theme(axis.line = element_blank(),
          axis.ticks = element_blank(),
          axis.text.x = element_text(angle = 45, hjust = 1))
```

函数 `compile_structure_plot_data`

输入参数表。

| 函数 | 描述 |
|----------------|---------|
| <code>L</code> | 主题比例矩阵。 |

| 函数 | 描述 |
|--------|------------------|
| topics | 所选主题的向量。即所选 L 列。 |

输出是包含三列的数据表。

| 函数 | 描述 |
|--------|----------------|
| sample | 数值型的 L 的行。 |
| topic | 主题。 |
| prop | 数值型的给定样本的主题比例。 |

```
compile_structure_plot_data <- function (L, topics) {
  n <- nrow(L)
  k <- length(topics)
  dat <- data.frame(sample = rep(1:n,times = k),
                     topic = rep(topics,each = n),
                     prop = c(L[,topics]))
  dat$topic <- factor(dat$topic,topics)
  return(dat)
}
```

函数 *compile_grouped_structure_plot_data*

相对于函数 *compile_structure_plot_data* 需要再输入 *gap*。

```
compile_grouped_structure_plot_data <- function (L, topics, grouping,
                                         gap = 0) {
  ticks <- rep(0,nlevels(grouping))
  names(ticks) <- levels(grouping)
  dat <- NULL
  m <- 0
  for (j in levels(grouping)) {
    i           <- which(grouping == j)
    out         <- compile_structure_plot_data(L[i,,drop = FALSE],topics)
```

```

out$sample <- out$sample + m
n           <- length(i)
dat         <- rbind(dat,out)
ticks[j]    <- m + n/2
m           <- m + n + gap
}
return(list(dat = dat,ticks = ticks))
}

```

函数 *structure_plot*【核心代码】

```

structure_plot <-
  function (fit, topics, grouping, loadings_order = "embed", n = 2000,
           colors = c("#e41a1c","#377eb8","#4daf4a","#984ea3","#ff7f00",
                      "#ffff33","#a65628","#f781bf","#999999"),
           gap = 1, embed_method = structure_plot_default_embed_method,
           ggplot_call = structure_plot_ggplot_call, ...) {

```

首先，检查输入变量。

其次，处理数据并绘制结构图。

```

# Prepare the data for plotting and create the structure plot.
fit$L <- fit$L[loadings_order,]
grouping <- grouping[loadings_order,drop = TRUE]
if (nlevels(grouping) == 1) {
  dat <- compile_structure_plot_data(fit$L,topics)
  return(ggplot_call(dat,colors))
} else {
  out <- compile_grouped_structure_plot_data(fit$L,topics,grouping,gap)
  return(ggplot_call(out$dat,colors,out$ticks))
}

```

6.2 other_plots.R

利用 `fit` 结果的输出 `progress` 绘制评价指标的曲线。

实现的主要函数是 `plot_progress` 和 `plot_loglik_vs_rank`。

为了实现上述主要函数，我们需要以下辅助函数，列表如下。

| 函数 | 描述 |
|---|---|
| <code>prepare_progress_plot_data</code> | 绘制评价指标与迭代次数的曲线图制作适合 <code>ggplot</code> 的数据集。 |
| <code>create_progress_plot</code> | 绘制评价指标与迭代次数的曲线图。 |
| <code>loglik_vs_rank_ggplot</code> | 绘制评价指标与主题数目 <code>K</code> 的曲线图。 |

具体代码如下。

函数 `prepare_progress_plot_data`

```
prepare_progress_plot_data <- function (fits, e) {
  n      <- length(fits)
  labels <- names(fits)
  for (i in 1:n) {
    y      <- fits[[i]]$progress
    y      <- cbind(data.frame("method" = labels[i]),y)
    y$timing <- cumsum(y$timing)
    fits[[i]] <- y
  }
  out           <- do.call(rbind,fits)
  out$method    <- factor(out$method,labels)
  out$loglik     <- max(out$loglik) - out$loglik + e
  out$loglik.multinom <- max(out$loglik.multinom) - out$loglik.multinom + e
  out$dev        <- out$dev - min(out$dev) + e
  return(out)
}
```

函数 `create_progress_plot`

```
create_progress_plot <- function (pdat, x, y, add.point.every, colors,
                                    linetypes, linesizes, shapes, fills,
                                    theme) {
  rows <- which(pdat$iter %% add.point.every == 1)
  if (x == "timing")
    xlab <- "runtime (s)"
  else if (x == "iter")
    xlab <- "iteration"
  if (y == "res")
    ylab <- "max KKT residual"
  else if (y == "dev")
    ylab <- paste("distance from best deviance")
  else if (y == "loglik" | y == "loglik.multinom")
    ylab <- paste("distance from best loglik")
  return(ggplot(pdat,aes_string(x = x,y = y,color = "method",
                                linetype = "method",size = "method")) +
    geom_line(na.rm = TRUE) +
    geom_point(data = pdat[rows,],
               mapping = aes_string(x = x,y = y,color = "method",
                                     fill = "method",shape = "method"),
               inherit.aes = FALSE,na.rm = TRUE) +
    scale_y_continuous(trans = "log10") +
    scale_color_manual(values = colors) +
    scale_linetype_manual(values = linetypes) +
    scale_size_manual(values = linesizes) +
    scale_shape_manual(values = shapes) +
    scale_fill_manual(values = fills) +
    labs(x = xlab,y = ylab) +
    theme())
}
```

函数 *loglik_vs_rank_ggplot_call*

```
loglik_vs_rank_ggplot_call <- function (dat, font.size = 9)
  return(ggplot(dat, aes_string(x = "x", y = "y")) +
    geom_line() +
    geom_point() +
    scale_x_continuous(breaks = dat$x) +
    labs(x = "rank, or number of topics (k)",
         y = "log-likelihood difference") +
    theme_cowplot(font.size))
```

6.3 embedding_plots.R 和 volcano_plots.R

`embedding_plots.R` 实现基于 PCA 的分析文本主题的算法，并依据 PCA 将文本根据主题聚合在一起以绘制结构图。

`volcano_plots.R` 实现绘制文本的主题分布的火山图。

7 数据模拟函数

`datasim.R` 实现模拟基因数据，这仅仅针对单细胞的 RNA 有效，当然与二倍体的 DNA 基因也有密切联系。主要实现了模拟基于 Poisson NMF 模型和主题模型的基因数据。使用了库 `stats` 和 `MCMCpack` 以调用分布函数。比如 `rnorm`、`runif`、`rmultinom`、`rpois`、`rdirichlet`。