



ОНЛАЙН-ОБРАЗОВАНИЕ

# Матричные Разложения

Дмитрий Музалевский  
Преподаватель



# План на сегодня

1. Матричные разложения. Ранг матрицы. Приближение
2. SGD и ALS. Прогнозирование значений. Implicit методы.
3. Практика



# Спектральное разложение

$$X = S^T \cdot D \cdot S,$$

где  $S$  — ортогональная матрица, а  $D = \text{diag}(\lambda_1, \dots, \lambda_i)$  — диагональная матрица из собственных значений матрицы  $X$ .

$$f(y) = y^T \cdot S^T \cdot D \cdot S \cdot y = (S \cdot y)^T \cdot D \cdot (S \cdot y) = z^T \cdot D \cdot z = \sum_{i=1}^n \lambda_i z_i^2,$$

где была введена естественная замена  $z = S \cdot y$ .



# Сингулярное разложение

В случае произвольной матрицы  $X$  имеет место так называемое сингулярное разложение. Пусть  $X$  — произвольная матрица, тогда существуют такие ортогональные матрицы  $U$  и  $V$ , а также диагональная матрица  $D$ , что:

$$X = U \cdot D \cdot V.$$



# Ранг Матрицы

Рангом (строчным и столбцовым) матрицы называется соответственно максимальное количество линейно независимых строк или столбцов. Одним из ключевых результатов линейной алгебры является то, что строчный ранг совпадает со столбцовым рангом и равен максимальному размеру невырожденной подматрицы. То есть ранг матрицы  $X \in \mathbb{R}^{n \times m}$  размера  $n \times m$  не может превосходить ни число строк, ни число столбцов в этой матрице:

$$X \in \mathbb{R}^{n \times m} \implies \text{rg}(X) \leq \min(n, m).$$



# Ранг Матрицы

$$X = AB, \quad A \in \mathbb{R}^{n \times k}, \quad B \in \mathbb{R}^{k \times m}.$$

В практических задачах данные всегда измеряются вместе с шумом и поэтому не вся информация, содержащаяся в матрице с данными представляет ценность для исследователя. Таким образом, ставится задача о нахождении лучшей аппроксимации исходной матрицы  $X$  некоторой матрицей, ранг которой не превосходит  $r < k$ . Любая матрица ранга  $r$  может быть представлена как произведение следующих матриц:

$$U \cdot V^T, \quad U \in \mathbb{R}^{m \times k}, \quad V \in \mathbb{R}^{n \times k}.$$



# Норма Матрицы

$$\|A\|_2 = \sqrt{\sum_{i,j} |a_{ij}|^2}.$$

В конечном итоге, задача приближения матрицы матрицей меньшего ранга примет вид:

$$U, V = \operatorname{argmin}_{U \in \mathbb{R}^{m \times k}, V \in \mathbb{R}^{n \times k}} \sum_{i,j} (x_{ij} - u_i v_j^T)^2,$$

а искомой матрицей, дающей наилучшее приближение при заданном ранге, будет матрица  $UV^T$ .



# Преобразование признаков

Пусть  $X$  — матрица признаков объектов. Пусть для  $X$  построено наилучшее приближение матрицей  $UV^T$  ранга  $k < n$ , где  $n$  — количество признаков в исходной задаче.

Матрица  $U$  может быть проинтерпретирована как матрица новых признаков тех же объектов. При этом размерность пространства признаков уменьшается — происходит сжатие с потерями, причем теряется минимум полезной информации.



# Рекомендации

Пусть  $X$  — матрица с оценками, которые поставил или поставил бы пользователь под номером  $i$  фильму под номером  $j$ . Поскольку далеко не все пользователи смотрели все фильмы и выставили оценку, известны не все элементы этой матрицы.

Чтобы спрогнозировать неизвестные данные, можно попытаться приблизить исходную матрицу с помощью матрицы меньшего ранга. В таком случае в качестве нормы следует использовать норму Фробениуса, где суммирование идет только по известным элементам матрицы  $X$ . После того, как наилучшее приближение по известным данным было найдено, эту матрицу можно использовать, чтобы спрогнозировать еще не известные данные.

	Пила	Улица Вязов	Ванильное небо	1 + 1
Маша	5	4	1	2
Юля	5	5	2	
Вова			3	5
Коля	3	?	4	5
Петя				4
Ваня		5	3	3



# Сингулярное разложение и низкоранговое приближение

Пусть задана матрица  $X$ . Требуется найти такую матрицу, ранг которой  $\text{rg } \hat{X} \leq k$ , которая наилучшим образом приближает исходную:

$$\hat{X} = \underset{\text{rg } \hat{X} \leq k}{\text{argmin}} \|X - \hat{X}\|$$

SVD для исходной матрицы имеет вид:

$$X = U \cdot D \cdot V^T,$$

где  $U$  и  $V$  — ортогональные (то есть и невырожденные) матрицы, а  $D$  — диагональная матрица ранга  $\text{rg } X$ . Можно сделать естественную замену искомой матрицы  $\hat{X}$  на матрицу  $\hat{D}$  (не обязательно диагональную, поэтому это тождественное преобразование):

$$\hat{X} = U \cdot \hat{D} \cdot V^T.$$

Задача переписется в виде:

$$\hat{X} = \underset{\text{rg } \hat{D} \leq k}{\text{argmin}} \|U \cdot (D - \hat{D}) \cdot V^T\| = \underset{\text{rg } \hat{D} \leq k}{\text{argmin}} \|D - \hat{D}\|.$$



# План на сегодня


1. Матричные разложения. Ранг матрицы. Приближение
2. **SGD и ALS. Прогнозирование значений. Implicit методы.**
3. Практика



# Матричное разложение: постановка задачи

$$X_{l,n} \approx U_{l,k} \cdot V_{k,n}^T,$$

где матрицы  $U$  и  $V$  задают новое признаковое описание объектов и изначальных признаков.





$$\|X - U \cdot V^T\| \rightarrow \min.$$

$$\sum_{i,j} (x_{ij} - \langle u_i, v_j \rangle)^2 \rightarrow \min,$$



# Сингулярное разложение

$$X = U\Sigma V^T,$$



## SGD

$$Q = \sum_{i,j} (\langle u_i, v_j \rangle - x_{ij})^2 \rightarrow \min_{u_i, v_j}.$$

$$\frac{\partial Q}{\partial u_i} = \sum_{i,j} \frac{\partial}{\partial u_i} (\langle u_i, v_j \rangle - x_{ij})^2 = \sum_j 2(\langle u_i, v_j \rangle - x_{ij}) \frac{\partial \langle u_i, v_j \rangle}{\partial u_i} = \sum_j 2(\langle u_i, v_j \rangle - x_{ij}) v_j.$$

$$u_i^{(t+1)} = u_i^{(t)} - \gamma_t \sum_j \varepsilon_{ij} v_j.$$

$$v_j^{(t+1)} = v_j^{(t)} - \eta_t \sum_i \varepsilon_{ij} u_i.$$

$$u_i^{(t+1)} = u_i^{(t)} - \gamma_t \varepsilon_{ij} v_j,$$

$$v_j^{(t+1)} = v_j^{(t)} - \eta_t \varepsilon_{ij} u_i.$$



# ALS и Регуляризация

$$\frac{\partial Q}{\partial u_i} = 0.$$

На следующей итерации находится новое значение  $v_j$ :

$$\frac{\partial Q}{\partial v_j} = 0.$$

$$\frac{\partial Q}{\partial u_i} = \sum_j 2(\langle u_i, v_j \rangle - x_{i,j})v_j = 0$$

$$\sum_j v_j \langle v_j, u_i \rangle = \sum_j x_{i,j} v_j$$

$$\left( \sum_j v_j v_j^T \right) u_i = \sum_j x_{i,j} v_j$$

$$\left( \sum_i u_i u_i^T \right) v_j = \sum_i x_{i,j} u_i$$

$$Q = \sum_{i,j} (\langle u_i, v_j \rangle - x_{i,j})^2 + \alpha \sum_i \|u_i\|^2 + \beta \sum_j \|v_j\|^2 \rightarrow \min_{u_i, v_j}$$



# Прогнозирование значений

$$x_{ij} \approx \langle u_i, v_j \rangle.$$

$$\sum_{i,j:x_{ij} \neq 0} (\langle u_i, v_j \rangle - x_{ij})^2 \rightarrow \min.$$

$$x_{ij} \approx \mu + \langle u_i, v_j \rangle,$$

$$x_{ij} \approx \mu + b_i^u + b_j^v + \langle u_i, v_j \rangle$$

$$\sum_{i,j} (\mu + b_i^u + b_j^v + \langle u_i, v_j \rangle - x_{ij})^2 \rightarrow \min$$

$$\sum_{i,j} (\mu + b_i^u + b_j^v + \langle u_i, v_j \rangle - x_{ij})^2 + \alpha \sum_i \|u_i\|^2 + \beta \sum_j \|v_j\|^2 + \gamma \sum_i b_i^{u^2} + \delta \sum_j b_j^{v^2} \rightarrow \min.$$



# Implicit методы

	Вечернее платье	Поднос для писем	iPhone 6s	Шуба D&G
Маша	1		1	
Юля	1	1		1
Вова		1	1	
Коля	1	?	1	
Петя		1	1	
Ваня			1	1



# Implicit методы

$$x_{ij} = 1 \approx \langle u_i, v_j \rangle$$
$$\sum_{i,j:x_{ij} \neq 0} (\langle u_i, v_j \rangle - x_{ij})^2 \rightarrow \min$$

$$u_i = \frac{1}{\sqrt{d}}(1 \dots 1)$$
$$v_j = \frac{1}{\sqrt{d}}(1 \dots 1)$$

- Explicit feedback: можно получить как положительные, так и отрицательные примеры (низкие и высокие оценки фильмов, лайки и дизлайки и т.д.)
- Implicit feedback: есть только положительные (лайки, покупки, просмотры) или отрицательные (дизлайки) примеры.



# Implicit методы

$$\sum_{i,j} w_{ij} (\langle u_i, v_j \rangle - x_{ij})^2 \rightarrow \min$$

$$w_{ij} = 1 + \alpha |x_{ij}|,$$



# План на сегодня

1. RNN
2. LSTM
- 3. Практика**





Спасибо  
за внимание!