

Визуализация больших данных

Максим Губин

Томск



На этой лекции будут рассмотрены

- ❖ Введение в визуализацию данных;
- ❖ Особенности визуализации больших данных;
- ❖ Kibana;
- ❖ Matplotlib.

Вступление





- ❖ Визуализация данных является ключевой частью любого рабочего процесса в науке о данных, но ее часто рассматривают как неудобный дополнительный шаг в отчете о результатах анализа.
- ❖ Принимать такую позицию – ошибочно: картинка стоит тысячи слов.

Зачем нужно визуализировать данные?

- ❖ Чтобы четко и эффективно донести информацию до пользователей;
- ❖ Чтобы помочь пользователям анализировать и рассуждать о данных и знаниях;
- ❖ Чтобы сделать сложные данные более доступными, понятными и удобными для использования;
- ❖ Чтобы помочь выявить закономерности, понять идеи, изучить источники данных.


Да, это все о пользователях. Но дело не в подаче менеджерам. Речь идет о повседневном анализе и принятии решений.

Квартет Энскомба






Параметр	Значение	Точность
Среднее x	9	точно
Дисперсия x	11	точно
Среднее y	7.50	до 2 знаков после запятой
Дисперсия y	4.125	+/- 0.003
Корреляция между x и y	0.816	до 3 знаков после запятой
Формула линейной регрессии	$y = 3.00 + 0.500x$	до 2 и 3 знаков после запятой соответственно
Коэффициент детерминации линейной регрессии	0.67	до 2 знаков после запятой

Декартовы координаты




- ❖ 2 оси
- ❖ Единицы измерения для каждой оси
- ❖ Координатная сетка
- ❖ Легенда

Декартовы координаты




Декартовы координаты


original data, linear scale




log-transformed data, linear scale



original data, logarithmic scale




logarithmic scale with incorrect axis title




Обращайте внимание на единицы изменения данных, особенно при использовании логарифмической шкалы.

Декартовы координаты

Логарифмические шкалы часто используются, когда набор данных содержит числа очень разных величин. В округах Техаса, показанных на рисунках, в самом густонаселенном округе (Харрис) согласно переписи 2010 года было 4092459 человек, а в наименее густонаселенном (Лавинг) - 82.




Texas counties, from most to least populous



Texas counties, from most to least populous

Цветовые шкалы: качественные

- ❖ Мы часто используем цвет как средство для различения отдельных предметов или групп, которые не имеют внутреннего порядка, таких как разные страны на карте или разные производители определенного продукта. В этом случае мы используем качественную цветовую шкалу.
- ❖ Такая шкала содержит конечный набор определенных цветов, которые выбираются так, чтобы они выглядели четко отличными друг от друга, а также были эквивалентны друг другу.
- ❖ Второе условие требует, чтобы ни один цвет не выделялся относительно других.
- ❖ И цвета не должны создавать впечатление порядка, как в случае с последовательностью цветов, которые становятся последовательно светлее



Цветовые шкалы: последовательные

- ❖ Цвет также можно использовать для представления численных данных, таких как доход, температура или скорость.
- ❖ В этом случае мы используем последовательную цветовую шкалу.
- ❖ Такая шкала содержит последовательность цветов, которые четко указывают (i), какие значения больше или меньше, чем другие, и (ii) насколько два конкретных значения удалены друг от друга.
- ❖ Второй момент подразумевает, что цветовая гамма должна восприниматься как равномерно изменяющаяся во всем диапазоне.

ColorBrewer Blues



Heat




Viridis



Цветовые шкалы: расходящиеся

- ❖ В некоторых случаях нам нужно визуализировать отклонение значений данных в одном из двух направлений относительно нейтральной средней точки.
- ❖ Одним простым примером является набор данных, содержащий как положительные, так и отрицательные числа. Мы можем захотеть показать те, которые имеют разные цвета, чтобы сразу стало ясно, является ли значение положительным или отрицательным, а также то, как далеко в любом направлении оно отклоняется от нуля.
- ❖ Подходящей цветовой шкалой в этой ситуации является расходящаяся цветовая гамма.
- ❖ Мы можем думать о расходящейся шкале как о двух последовательных шкалах, соединенных вместе в общей средней точке, которая обычно представлена светлым цветом.




Цветовые шкалы: акцент

- ❖ Цвет также может быть эффективным инструментом для выделения определенных элементов в данных.
- ❖ В наборе данных могут быть определенные категории или значения, которые содержат ключевую информацию об истории, которую мы хотим рассказать, и мы можем усилить историю, выделив читателю соответствующие элементы фигуры.
- ❖ Простой способ добиться этого - раскрасить элементы фигуры цветом или набором цветов, которые ярко выделяются на фоне остальной части фигуры. Этот эффект может быть достигнут с помощью **акцентирующих** цветовых шкал, которые представляют собой цветовые шкалы, которые содержат как набор приглушенных цветов, так и соответствующий набор более сильных, темных и / или более насыщенных цветов.

Okabe Ito Accent




Grays with accents




ColorBrewer Accent





Визуализация численных величин: столбчатые диаграммы





Визуализация численных величин: столбчатые диаграммы





Визуализация численных величин: столбчатые диаграммы





Визуализация численных величин: столбчатые диаграммы



Визуализация численных величин: столбчатые




Комбинации столбчатых диаграмм



❖ Столбчатые диаграммы с группировкой позволяют показать множество данных за раз, но их труднее воспринимать.


❖ Всегда выбирайте условие группировки, связанное с историей, которую вы хотите показать вашей визуализацией.

Комбинации столбчатых диаграмм





❖ Иногда проще воспринять несколько столбчатых диаграмм, чем одну сгруппированную.



❖ Вместо того, чтобы рисовать группы столбцов рядом, иногда предпочтительнее складывать столбцы друг на друга. Такое объединение полезно, когда сумма величин, представленных отдельными столбцами, сама по себе является значимой.



Точечные графики



Тепловые карты







Тепловые карты позволяют отобразить динамику развития данных, подобно множеству графиков, но с сохранением читаемости.




Для тепловых карт также критически важно выбрать условие упорядочивания строк, связанное с теми особенностями данных, на которые вы хотели бы обратить внимание.

Гистограммы




При создании
гистограммы всегда
нужно попробовать
несколько возможных
значений ширины столбца
(bin).

Диаграмма плотности




- ❖ На графике плотности мы пытаемся визуализировать базовое распределение вероятности данных, рисуя соответствующую непрерывную кривую.
- ❖ Эта кривая должна быть построена из данных, и наиболее часто используемый метод для этой процедуры оценки называется оценкой плотности ядра.
- ❖ При оценке плотности ядра мы рисуем непрерывную кривую (ядро) с небольшой шириной (контролируемой параметром, называемым полосой пропускания) в местоположении каждой точки данных, а затем складываем все эти кривые, чтобы получить окончательную оценку плотности.
- ❖ Наиболее широко используемым ядром является ядро, но есть много других вариантов.

Диаграмма плотности



При создании диаграмм плотности всегда нужно попробовать несколько возможных значений полосы пропускания (bandwidth).


Диаграмма плотности



Оценки плотности ядра имеют тенденцию приводить к появлению данных там, где их нет, особенно в хвостах. Как следствие, небрежное использование оценок плотности может легко привести к явно неверным визуализациям. Например, визуализацию распределения по возрасту, которая включает отрицательный возраст.


Всегда проверяйте, что ваша оценка плотности не приводит к появлению бессмысленных значений.

Несколько распределений на одной визуализации



- ❖ Гистограмма возрастов пассажиров Титаника с разделением по полу.
- ❖ Гистограммы с накоплением легко спутать с перекрывающимися гистограммами.
- ❖ Кроме того, высоты столбцов, представляющих пассажиров женского пола, нельзя легко сравнить друг с другом.


Несколько распределений на одной визуализации




Теперь кажется, что на самом деле есть три разные группы, а не две, и мы до сих пор не до конца уверены, где начинается и заканчивается каждая полоса.

Перекрывающиеся гистограммы не работают должным образом, потому что полупрозрачная полоса, нарисованная поверх другой, имеет тенденцию не выглядеть как полупрозрачная полоса, а вместо этого похожа на полосу, нарисованную другим цветом.

Несколько распределений на одной визуализации




Несколько распределений на одной визуализации




Решение, которое хорошо работает для этого набора данных, состоит в том, чтобы показать распределение по возрасту пассажиров мужского и женского пола по отдельности, каждое из которых как часть общего распределения по возрасту.

Несколько распределений на одной визуализации





Наконец, когда мы хотим визуализировать ровно два распределения, мы также можем создать две отдельные гистограммы, повернуть их на 90 градусов и сделать так, чтобы столбцы в одной гистограмме указывали в противоположном направлении от другого. Этот трюк обычно используется при визуализации возрастных распределений, а получающийся график обычно называется *возрастной пирамидой*

Круговые диаграммы





Круговая диаграмма разбивает круг на срезы, так что площадь каждого среза пропорциональна доле итога, которую он представляет. Эту же процедуру можно выполнить для прямоугольника, и в результате получается столбчатая диаграмма с суммированием.

Круговые диаграммы



- ❖ Для сравнения, столбчатая диаграмма облегчает прямое сравнение трех групп, хотя и затеняет другие аспекты. Так, отношение каждого столбца к общему числу не является визуально очевидным.
- ❖ Помните: вам всегда нужно выбирать визуализацию, которая наилучшим образом соответствует вашему конкретному набору данных и выделяет ключевые особенности данных, которые вы хотите подчеркнуть.



Круговые диаграммы с подкатегориями



Круговые диаграммы можно делать с разбиением частей на ещё более мелкие части, но такие диаграммы трудно воспринимаются.


Диаграмма, где каждый подэлемент – наивысшего уровня, и группировка показана цветом, воспринимается лучше.

Диаграммы рассеяния




- ❖ Многие наборы данных содержат две или более количественных переменных, и нас может интересовать, как эти переменные связаны друг с другом.
- ❖ Чтобы построить отношения только двух таких переменных, например, рост и вес, обычно применяют диаграмму рассеяния.
- ❖ Если нужно показать более двух переменных разом, можно использовать пузырьковую диаграмму.

Пузырьковые диаграммы




- ❖ Главный недостаток пузырьковых диаграмм в том, что они показывают одинаковые типы переменных, количественные переменные, с двумя различными типами шкал, положением и размером.
- ❖ Это затрудняет визуальное выявление сильных связей между различными переменными.
- ❖ Более того, различия между значениями данных, закодированных как размер пузырьков, сложнее воспринимать, чем различия между значениями данных, закодированными как положение.
- ❖ Поскольку даже самые большие пузырьки должны быть маленькими по сравнению с общим размером фигуры, различия в размерах даже между самыми большими и самыми маленькими пузырьками обязательно будут небольшими.
- ❖ Следовательно, меньшие различия в значениях данных будут соответствовать очень маленьким различиям в размерах, которые практически невозможно увидеть.

Временные ряды



❖ Важная особенность временных рядов: у каждой точки есть строго заданные левый и правый соседи, строго по одному, и интервалы по оси X между точками одинаковы.

❖ Мы можем визуально подчеркнуть это, соединяя соседние точки линиями.




❖ Некоторые люди возражают против рисования линий между точками, потому что линии не представляют наблюдаемые данные. В частности, если бы только несколько наблюдений были расположены далеко друг от друга, если бы наблюдения проводились в промежуточное время, они, вероятно, не попали бы точно в показанные линии.



❖ Таким образом, в некотором смысле, линии не соответствуют реальным данным.

❖ Тем не менее, они могут помочь с восприятием, когда точки разнесены далеко или неравномерно.

❖ Мы можем в некоторой степени решить эту дилемму, указав ее в подписи к рисунку, например, написав «линии приведены для иллюстрации».





Тренды



- ❖ Акт сглаживания создает функцию, которая сохраняет важные закономерности в данных, удаляя ненужные незначительные детали или шумы.
- ❖ Финансовые аналитики обычно сглаживают данные фондового рынка, вычисляя скользящие средние.
- ❖ Чтобы сгенерировать скользящее среднее, мы берем временное окно, скажем, первые 20 дней во временном ряду, вычисляем среднюю цену за эти 20 дней, затем перемещаем временное окно на один день, так что теперь оно охватывает 2-й и 21-й день, вычислите среднее значение за эти 20 дней, снова переместите временное окно и т. д. Результатом является новый временной ряд, состоящий из последовательности усредненных цен.
- ❖ Чтобы построить эту последовательность скользящих средних, нам нужно решить, какой конкретный момент времени связать со средним для каждого временного окна.
- ❖ Финансовые аналитики часто отображают каждое среднее значение в конце соответствующего временного окна. Этот выбор приводит к кривым, которые отстают от исходных данных (рисунок а), с более серьезными задержками, соответствующими большим временным окнам усреднения.
- ❖ Статистики, с другой стороны, строят среднее значение в центре временного окна, в результате чего получается кривая, идеально наложенная на исходные данные.

2D-гистограммы



- ❖ 2D-гистограмма концептуально похожа на одномерную гистограмму, как обсуждалось в главе 7, но теперь мы объединяем данные в двух измерениях.
- ❖ Мы подразделяем всю плоскость $x - y$ на маленькие прямоугольники, подсчитываем, сколько наблюдений приходится на каждый из них, и затем окрашиваем прямоугольники по этому количеству.

Визуализация должна содержать историю

Большая часть визуализации данных делается с целью общения.

У нас есть представление о наборе данных, и у нас есть потенциальная аудитория, и мы хотели бы донести нашу информацию до нашей аудитории.

Чтобы успешно донести наше понимание, нам нужно будет представить зрителям ясную и захватывающую **историю**.

Потребность в истории может раздражать ученых и инженеров, которые могут приравнять ее к придумыванию, продаже результатов.

Тем не менее, эта точка зрения упускает важную роль, которую истории играют в рассуждениях и памяти.

Любое общение создает историю в умах аудитории.


Если мы сами не представим ясную историю, то наша аудитория создаст ее за нас.

В лучшем случае эта история будет достаточно близка нашему взгляду на представленный материал.

Тем не менее, это может быть и часто намного хуже. Придуманная история может быть «это скучно», «автор неправ» или «автор некомпетентен».


Ваша цель в рассказывании истории должна состоять в том, чтобы использовать факты и логические рассуждения, чтобы заинтересовать аудиторию.

Частые ошибки использования цвета




Используйте прямую маркировку вместо цветов, когда нужно различать более восьми категорий.

Частые ошибки использования цвета



Избегайте больших
заполненных областей
чрезмерно насыщенных
цветов. Они мешают
вашему читателю
воспринимать ваши
данные.

Частые ошибки использования цвета



rainbow scale




rainbow converted to grayscale



Цветовая гамма радуги очень немонотонна. Это становится ясно видимым путем преобразования цветов в значения серого.

Слева направо шкала меняется от умеренно темной до светлой до очень темной и обратно до умеренно темной.

Частые ошибки использования цвета





Частые ошибки использования цвета: дальтонизм




- ❖ По первым двум примерам может показаться, что почти невозможно найти два контрастных цвета, которые безопасны при всех формах нарушений цветовосприятия.
- ❖ Однако ситуация не так страшна. Часто можно внести небольшие изменения в цвета, чтобы они имели желаемый вид, а также были различимы людьми с ограниченными возможностями.
- ❖ Например, шкала ColorBrewer PiYG (от розового до желто-зеленого) выглядит красно-зеленой для людей с нормальным цветовым зрением, но остается различимой для людей с проблемами цветовосприятия.

Частые ошибки композиции: легенда




Частые ошибки композиции: шкалы




Частые ошибки композиции: 3D


a




b




c





d



Частые ошибки композиции: 3D




Частые ошибки композиции: 3D




sequence conservation



Частые ошибки композиции: нагроможденность




Частые ошибки композиции: нагроможденность




Примеры реальных диаграмм


pandalogs - avg request execution time by host



pandalogs - request count by host



Визуализация больших данных



- ❖ Отображение миллионов точек данных в одной визуализации почти всегда делает визуализацию загроможденной до степени нечитаемости.
- ❖ Решение этой проблемы требует группировки, агрегирования данных или построения репрезентативных выборок.
- ❖ Круговые, линейные, гистограммы и диаграммы рассеяния могут быть очень полезны для отображения агрегированных данных.







Matplotlib

- ❖ Matplotlib это самая большая и мощная из библиотек визуализации, доступных в Python.
- ❖ Она мощная, гибкая, и имеет огромный выбор визуализаций.
- ❖ Для начинающего пользователя, она может показаться слишком сложной.
- ❖ Вы можете потратить много времени на работу со всеми доступными опциями, даже если все, что вам нужно, - это создать простой точечный график.


matplotlib

Matplotlib - самый популярный инструмент визуализации для Python, поэтому вы никогда не будете одиноки в случае возникновения проблем.


Matplotlib




Matplotlib: 2-мерная гистограмма




Matplotlib: диаграмма рассеяния




Matplotlib: 2 миллиона элементов на 2d-гистограмме




Matplotlib: интересные закономерности поведения задач WLCG




Matplotlib: гистограмма



Matplotlib: диаграмма рассеяния





Kibana





- ❖ Веб-приложение для исследования и визуализации данных
- ❖ Современный браузерный интерфейс (HTML5 + JavaScript)
- ❖ Поставляется с собственным веб-сервером для простой настройки
- ❖ Полная интеграция с Elasticsearch

Kibana: обнаружение данных



Kibana: создание визуализаций




Kibana: разные типы визуализаций





Create a new visualization

Step 1




 Area chart	Great for stacked timelines in which the total of all series is more important than comparing any two or more series. Less useful for assessing the relative change of unrelated data points as changes in a series lower down the stack will have a difficult to gauge effect on the series above it.
 Data table	The data table provides a detailed breakdown, in tabular format, of the results of a composed aggregation. Tip, a data table is available from many other charts by clicking grey bar at the bottom of the chart.
 Line chart	Often the best chart for high density time series. Great for comparing one series to another. Be careful with sparse sets as the connection between points can be misleading.
 Markdown widget	Useful for displaying explanations or instructions for dashboards.
 Metric	One big number for all of your one big number needs. Perfect for show a count of hits, or the exact average a numeric field.
 Pie chart	Pie charts are ideal for displaying the parts of some whole. For example, sales percentages by department. Pro Tip: Pie charts are best used sparingly, and with no more than 7 slices per pie.
 Tile map	Your source for geographic maps. Requires an elasticsearch geo_point field. More specifically, a field that is mapped as type:geo_point with latitude and longitude coordinates.
 Vertical bar chart	The goto chart for oh-so-many needs. Great for time and non-time data. Stacked or grouped, exact numbers or percentages. If you are not sure which chart your need, you could do worse than to start here.

Kibana Dashboard



Kibana: основные элементы интерфейса



The screenshot shows the Kibana interface with the following labeled components:

- Index Pattern:** Points to the search bar containing the index pattern `logstash-*`.
- Query bar:** Points to the search bar area.
- Time Picker:** Points to the time range selector showing `May 17th 2015, 04:00:41.685 to May 20th 2015, 18:32:51.964`.
- Toolbar:** Points to the top navigation bar with buttons for `New`, `Save`, `Open`, and `Share`.
- Side Navigation:** Points to the left sidebar menu with options like `Discover`, `Visualize`, `Dashboard`, `Timelion`, `Management`, and `Dev Tools`.
- Histogram:** Points to the bar chart showing the distribution of data over time.
- Document Table:** Points to the table of search results below the histogram.

The histogram shows a periodic distribution of data points over time, with peaks occurring roughly every 24 hours. The x-axis is labeled `utc_time per hour` and the y-axis is labeled `Count`.

The document table shows the following data:

Time	_source
May 18th 2015, 02:03:25.877	<code>@timestamp: May 18th 2015, 02:03:25.877 ip: 185.124.182.126 extension: gif response: 404 geo.coordinates: { "lat": 36.518375, "lon": -86.05828083 } geo.src: PH geo.dest: MM geo.srcdest: PH:MM @tags: success, info utc_time: May 18th 2015, 02:03:25.877 referer: http://twitter.com/error/will</code>
May 18th 2015, 05:28:25.013	<code>@timestamp: May 18th 2015, 05:28:25.013 ip: 79.1.14.87 extension: gif response: 200 geo.coordinates: { "lat": 35.16531472, "lon": -107.9006142 } geo.src: GN geo.dest: US geo.srcdest: GN:US @tags: success, info utc_time: May 18th 2015, 05:28:25.013 referer: http://www.slate.com/warning/</code>

Заключение

- ❖ Помните: большинство всех возможных визуализаций больших данных на самом деле не делаются с самими большими данными, они обычно основаны на предварительно обработанных выборках данных.
- ❖ Вы не обязаны использовать специализированные инструменты для визуализации, если вам не нужны ваши графики **быстро**.
- ❖ Таким образом, вы можете свободно использовать любые инструменты визуализации, которые вы предпочитаете.
- ❖ Кибана не обязательна, но удобна.

Спасибо за внимание!

mgubin@tpu.ru

econophysics 