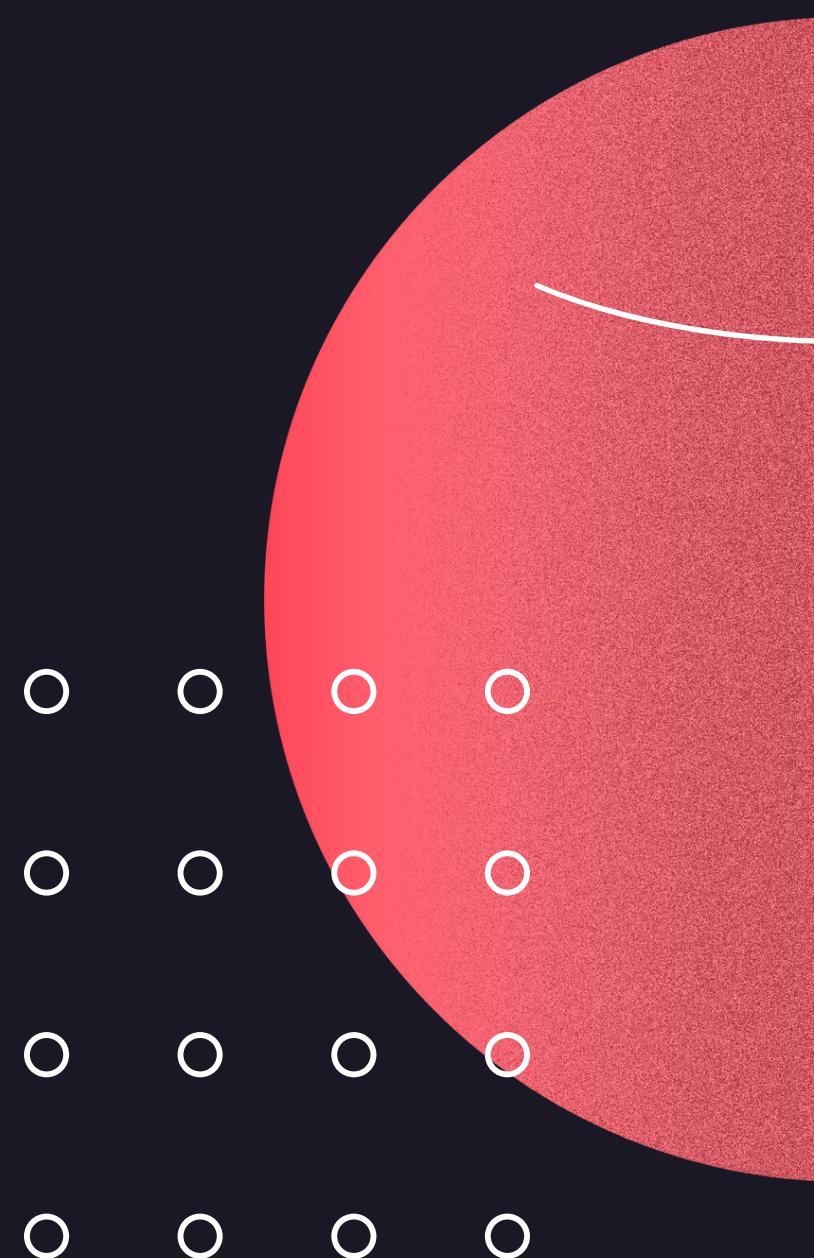


Crossing pedagogical boundaries with open data

Santeri Koivula, Peitsa Veteli
and Veera Juntunen
Helsinki Institute of Physics HIP

The agenda



- What is this about?
- Exercise: What is the Jupyter Notebook?
- Going through an advanced example
- Website
- Feedback

Open data is everywhere — CERN, NASA, The World Bank, etc.

Our mission is to help teachers to create research-based exercises for their courses using open data. Multidisciplinarity; curiosity; and skills for data analysis are at the heart of what we do.

We have created study materials, organized workshops for teachers, and helped teachers to use open data in their classes.



WHAT IS THIS ABOUT?

WHY?

WHY?

Future citizenship -
understanding, analyzing
information and
assessing its credibility

Getting acquainted with
the tools of science

Multidisciplinary
learning

The amount of data is
rising

Communication skills

Understanding large
phenomena and
different contexts

Ability to understand
and question

THE PERSPECTIVE OF A STUDENT

In its simplest form, the student is provided with a link of an exercise that uses open data. An exercise can be saved either as a notebook or a PDF file.

The exercises can also work as a tool for a student to reflect on their learning, in which case other programs or platforms are not even needed.

Easy!

06

VISUALIZING DATA

INFORMATIVE
COMMUNICATION

UNDERSTANDING DATA

ASSESSING
CREDIBILITY

PROGRAMMING

SEARCHING FOR
DATA

FINDING
REPEATING
PATTERNS



What kind of materials?

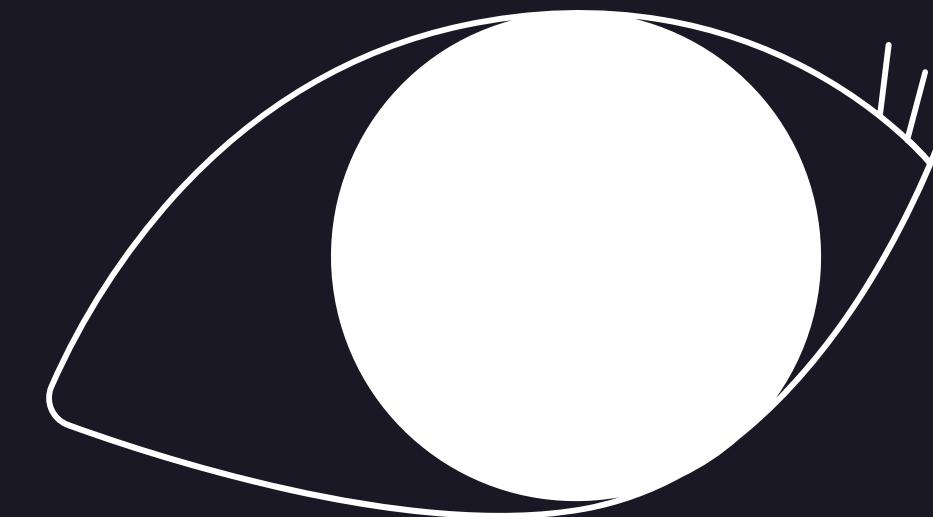
How much coding?

How much can students influence
on the exercises?

Do you want to make materials
by yourself?

What is the group size?

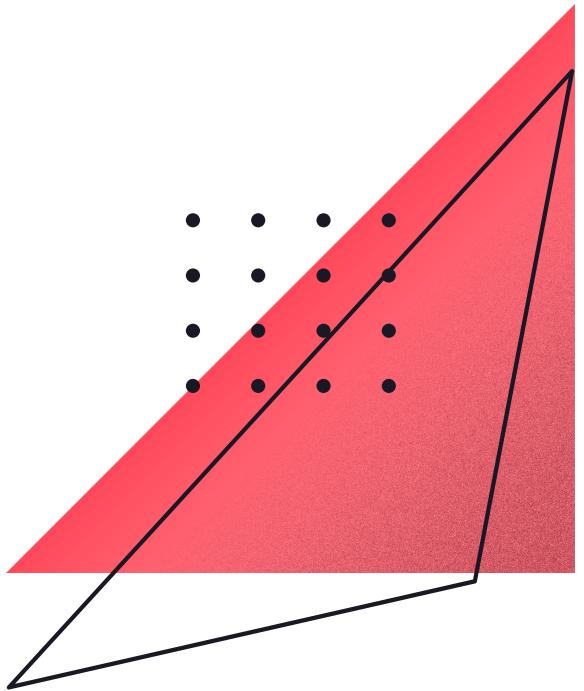
Returning the exercises?



HOW MUCH WORK FOR TEACHERS?

BEGINNER – INTERMEDIATE – EXPERT

WHAT OUR EXERCISES LOOK LIKE



Plotting the invariant mass histogram

In this excercise, we learn how to plot the histogram of invariant masses with Python. Let us use the data collected by the CMS detector in 2011 [1]. Events with specific criteria [2] have been selected in the CSV file `Ymumu_Run2011A.csv`, which we are using.

Explore the different code cells below and run the code. Note that normally the code would not be commented as much as this. Here, the reason for these comments is to explain in detail what the code is doing.

[1] CMS collaboration (2016). DoubleMu primary dataset in AOD format from RunA of 2011 (/DoubleMu/Run2011A-12Oct2013-v1/AOD). CERN Open Data Portal. DOI: [10.5281/zenodo.107483](https://doi.org/10.5281/zenodo.107483).

[2] Thomas McCauley (2016). Ymumu. Jupyter Notebook file. <https://github.com/tmcrae/cmssw-jupyter/blob/hst-0.1/Ymumu.ipynb>.

1) Start

```
# Import the needed modules. Pandas is for the data-analysis
# and matplotlib.pyplot for making plots. Modules are named as pd and plt.
import pandas as pd
import matplotlib.pyplot as plt

# Jupyter Notebook uses "magic functions". With this function it is possible to plot
# the histogram straight to notebook.
%matplotlib inline
```

2) Getting the data

```
# Create a new DataFrame structure from the file "Ymumu_Run2011A.csv"
dataset = pd.read_csv('.../Data/Ymumu_Run2011A.csv')

# Create a Series structure (basically a list) and name it "invariant_mass".
# Save the column "M" from the "dataset" to the variable "invariant_mass".
invariant_mass = dataset['M']
```

3) Plotting the histogram

Now we can create and plot the histogram of the values of the invariant masses. The histogram shows for how many events the invariant mass of the muon pair is in a certain value range. Note that we will use total 500 bins in the histogram, so you will not spot the separate bins because there are so many of them.

```
# Plot the histogram with the function hist() of the matplotlib.pyplot module:
# (http://matplotlib.org/api/pyplot_api.html?highlight=matplotlib.pyplot.hist#matplotlib.pyplot
# 'Bins' determines the number of bins used.
plt.hist(invariant_mass, bins=500)

# Name the axes and give a title.
plt.xlabel('Invariant mass [Gev]')
plt.ylabel('Number of events')
plt.title('The histogram of the invariant masses of two muons \n') # \n creates a new line for

# Show the plot.
plt.show()
```

The histogram of the invariant masses of two muons

4) Analysis

- What does the histogram tell us?
- What happens around the mass 9.5 GeV?

Previous
[Calculating the invariant mass](#)

Next
[Advanced](#)

By HIP Education and Open Data Team

Development of this material is made possible by a grant from Finnish National Agency of Education

The material on this website is licenced under CC-BY 4.0. licence.

DIFFERENT SUBJECTS

Open data can be used in many different subjects.

In Finnish we have materials on physics, biology, text analysis, geography, and mathematics.

Similar exercises could be used in other fields as well, such as history, economics, and psychology.

Pumpit - saastumislähteet ja terveysmaantiede

Tässä osiossa käytetään autenttisia tietoja tapahtumista elo-syyskuussa 1854.

John Snow kuuli asiasta 4.9. ja käytti seuraavat kolme päivää juosten ympäriinsä keräämässä aineistoja, piirtäen karttoja ja vakuuttaen paikallishallintoa tarpeellisista vastatoimista. Jokainen tuhlahti hetki tarkotti lisää tartuntoja ja kuolleita.

```
# AJA NÄMÄ PAKETIT ENSIN, JOLLET AJANUT EDELLISTÄ OSIOTA
import pandas as pd
import matplotlib.pyplot as plt
import random as rnd
import numpy as np
```

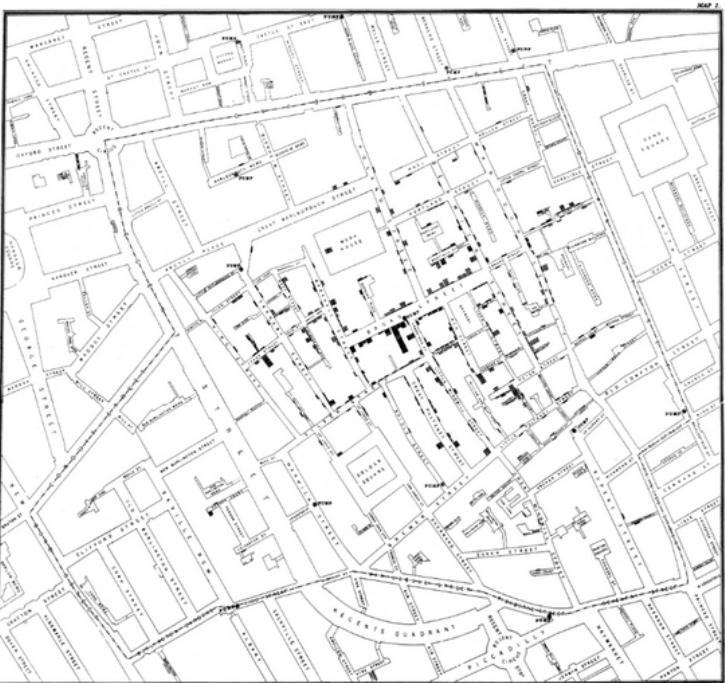
```
# Historiallinen data, joka on kerätty Robin Wilsonin julkaisemista paketeista
# tällä http://blog.rtwilson.com/john-snows-cholera-data-in-more-formats/
ajat = pd.read_csv("../data/johnsnow_dataset_dates_all.csv")
kuolinluvut = pd.read_csv("../data/johnsnow_dataset_deaths.csv")
pumput = pd.read_csv("../data/johnsnow_dataset_pumps_names.csv")
```

```
# Tästä nähdään tapahtumien aikakehitys.
plt.figure(figsize=(20,5))
plt.plot(ajat['date'], ajat['attacks'], label = 'Sairastumiset')
plt.plot(ajat['date'], ajat['deaths'], label = 'Kuolemat')
plt.xticks(rotation='45')
plt.legend(fontsize = 20)
plt.title('Päivittäiset uudet tapaukset \n', fontsize = 20)
plt.show()
```



Yllä olevasta kuvajasta nähdään naapuruston sairastapausten räjähtävän käsii kuun taitteessa. Myöhemmissä arvioissa Snow on uskonut taudin olleen jo luonnostaan laskussa toimiensa aikana (esimerkiksi ihmisten karattua paikalta), mutta joitain ratkaisevia tapauksia vuoden 8.9., mikä katkaisee isomman levämisen lähes samantien.

Snow kiersi paikanpäällä aikansa, mutta yhden ihmisen tiedonkeruuoperaatio kuolevien ihmisten, paettessa hylättyjen talojen ja yleisen kaooksen keskellä olisi tullut liian hitaaksi. Sen sijaan tohtorimme käännytti tehotkaampaan suuntaan ja marssi paikallisen tilastokeskuksen, Office of Register Generalin, puheille ja vaati käytöön sähkäkkien kuolintapausten ajat ja osoitteet. Alla on alueen kartta, mihin hän merkkiä kuolleet mustina vaakavivoina kuin vierekkäiset hauta-arkut piholle.



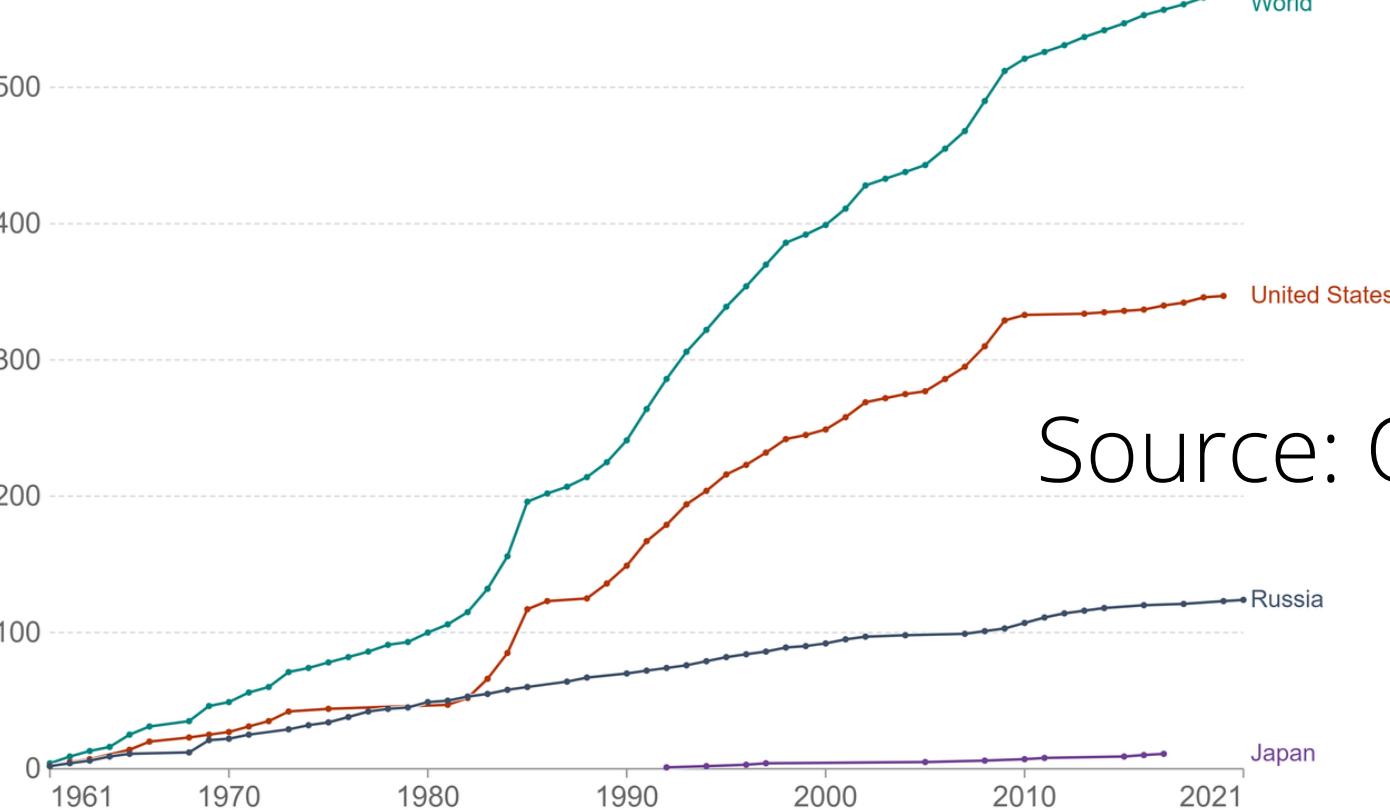
Tehtävä 2:

Katsomalla yllä olevaa karttaa, mitä voit sanoa kuolintapausten asettumisesta kartalle?

Cumulative number of people who have been to space, 1961 to 2021

For individuals who have been to space multiple times, only the date of their first visit is shown.

Our Wo
in Dat



Source: Our World In Data

10

```
# Valmistellaan kuva, tehdään kuvasta suuri ja asetetaan taustaväriksi sininen
fig, ax = plt.subplots(1, figsize=(50,20), facecolor='lightblue')

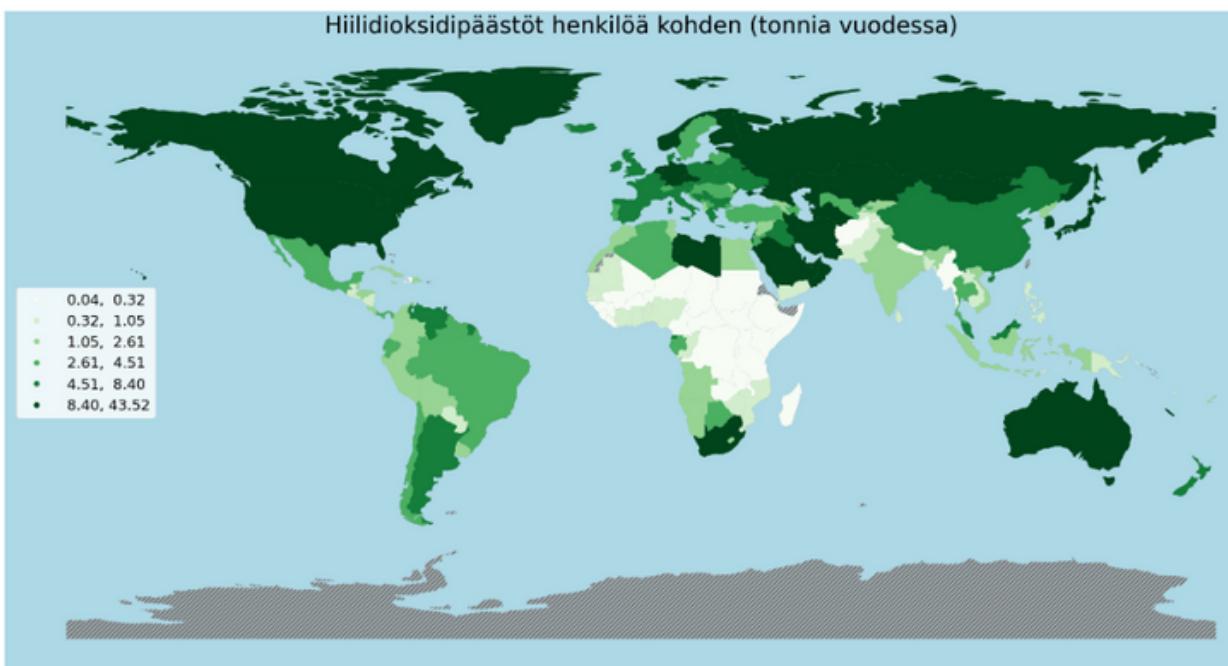
# Piirretään taustaksi kaikki maat ja täytetään ne viivoilla.
# Tällöin ne maat, joista ei ole dataa, erottuvat helpommin.
world.plot(ax=ax, color='darkgrey', alpha=0.8, hatch= "///")

# Piirretään data taustan päälle
data.plot(
    column='2014 [YR2014]', # Määritetään piirrettävä sarake
    ax=ax, # Piirretään kuva samalle akselille kuin tausta
    cmap='Greens', # Käytetään vihreää värikarttaa
    legend=True, # Lisätään selite
    legend_kwds={ # Asetetaan selitteen fonttikoko
        'fontsize': 25, # Asetetaan selitteen fonttikoko
        'loc':'center left' # Asetetaan selitteen sijainti
    },
    scheme='quantiles', # Jaetaan datan värit samankokoisiin osiin
    k=6 # Valitaan osien lukumääräksi 6
)

# Lisätään kuvalle otsikko
plt.title('Hiilidioksidipäästöt henkilöä kohden (tonnia vuodessa)', fontsize = 40)

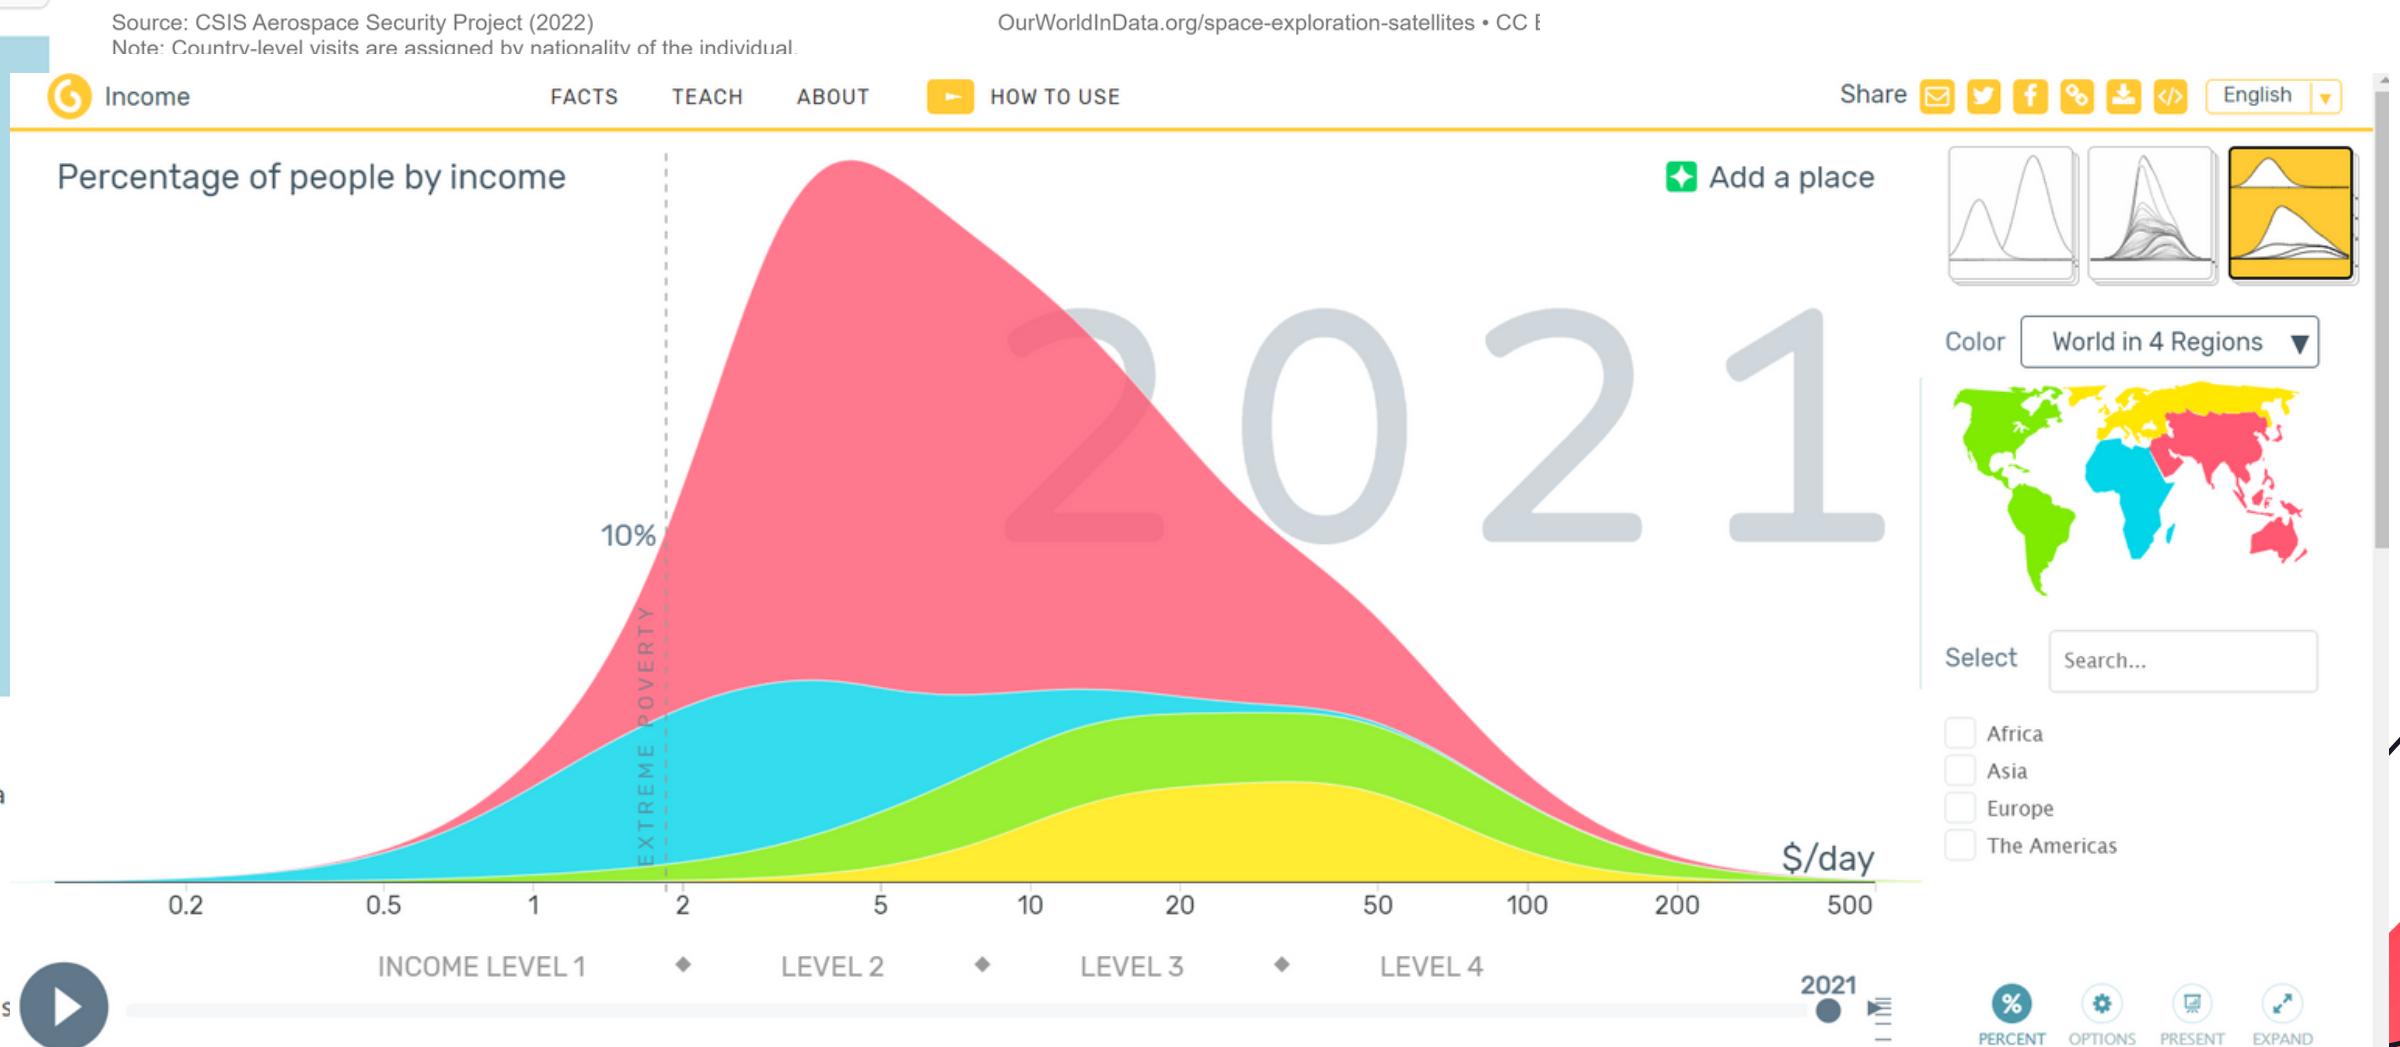
# Poistetaan akselit kuvan reunoilta
ax.axis('off')

# näytetään kuva
plt.show()
```



Nyt kartasta erottaa jo huomattavasti paremmin eri alueet ja niitä vastaavat hiilidioksidipäästöt. Voit kokeilla piirtää datan myös jakamalla datan useampaan tai vähempään kuin kuuteen osaan. Miltä data tällöin näyttää? Muokkaa kuva haluamallasi tavalla.

Etsi itse jokin toinen valtiokohtainen data ja piirrä se samaan tapaan. Valtiokohtaista dataa löytää googlaamalla tai esimerkiksi osoitteesta <https://databank.worldbank.org/source/world-development-indicators#>. Maailmanpankin sivuilta pystyy myös tarkastelemaan dataa kartalla, mutta kokeile piirtää itselle!



Source: Gapminder

PROJECTS

2021

HEALTH EDUCATION

Autumn 2021

PROGRAMMING

Autumn 2021

BIOLOGY

Autumn 2021

Spring 2022

SCIENCE COURSE

Spring 2022

Autumn 2022

SCIENCE COURSE

Autumn 2022

CLIMATE THEME DAY

Autumn 2022

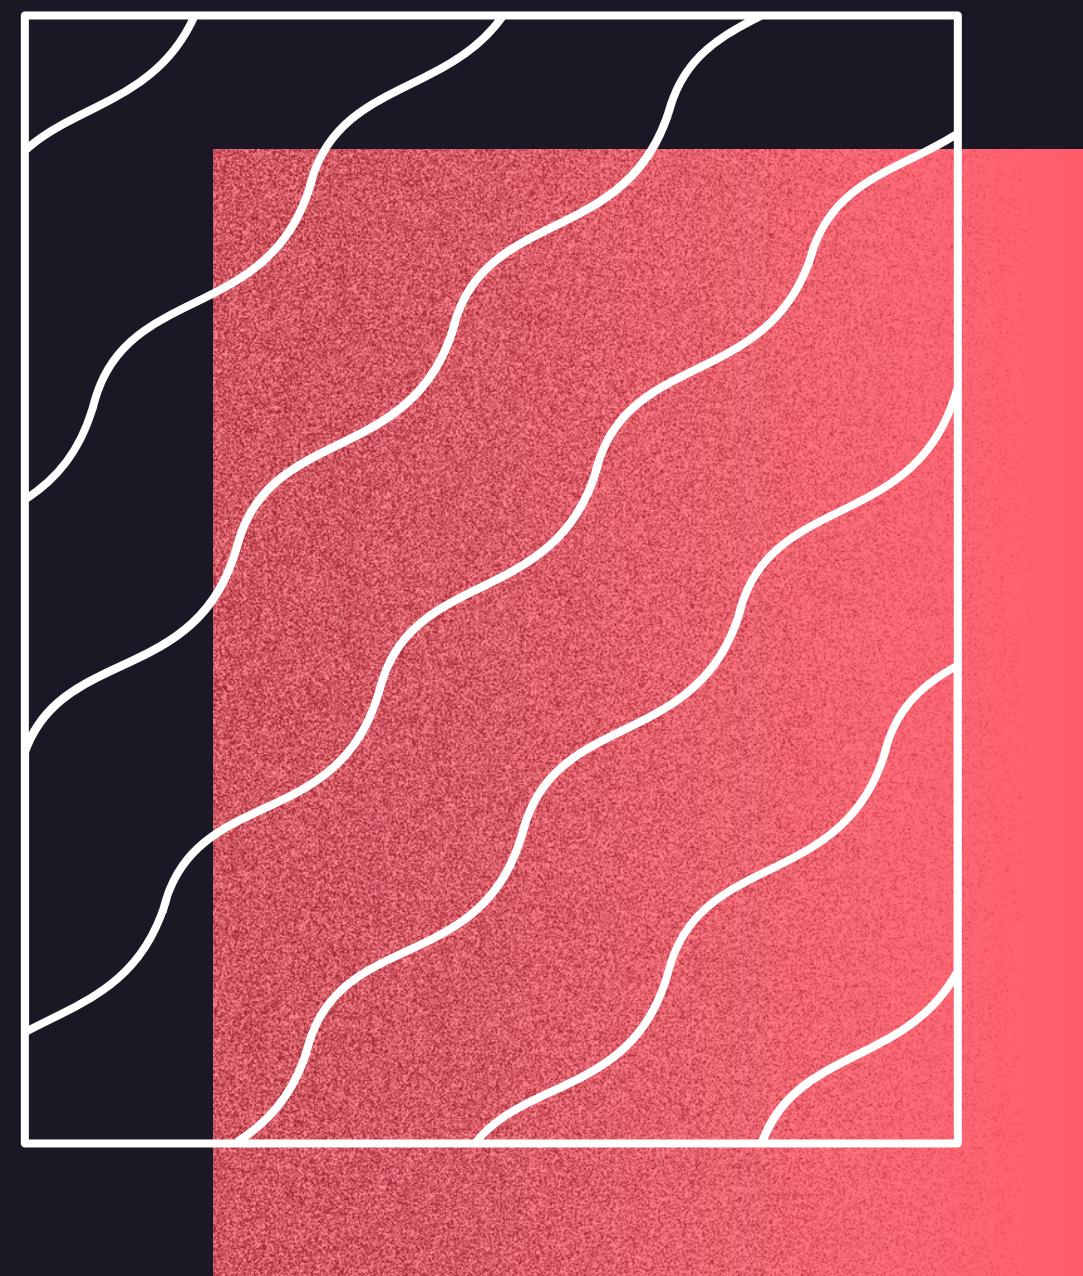
Teacher training

Workshops

Classes

Theme days

individual work – groupwork – laboratory work – essays – analyses – research work



Versatility - text, code,
images, videos, animations

Students can return one
document only

... What about Excel?

WHY LEARN A NEW PLATFORM?

Everything from instructions
to exercises are in the
same place

Teacher can easily run the
commands again while
going over the results



NEXT

1. Jupyter Notebook -exercise
2. Going through an advanced example
3. Our website

CONTACT US

Peitsa Veteli

peitsa.veteli@helsinki.fi

Veera Juntunen

veera.juntunen@helsinki.fi

Santeri Koivula

santeri.jan.viliam.koivula@cern.ch

WEBSITE and materials

<https://opendata-education.github.io/en/>

You can find everything you need to get started from our website, such as materials that are ready to use or to modify, and links to websites that publish open data.

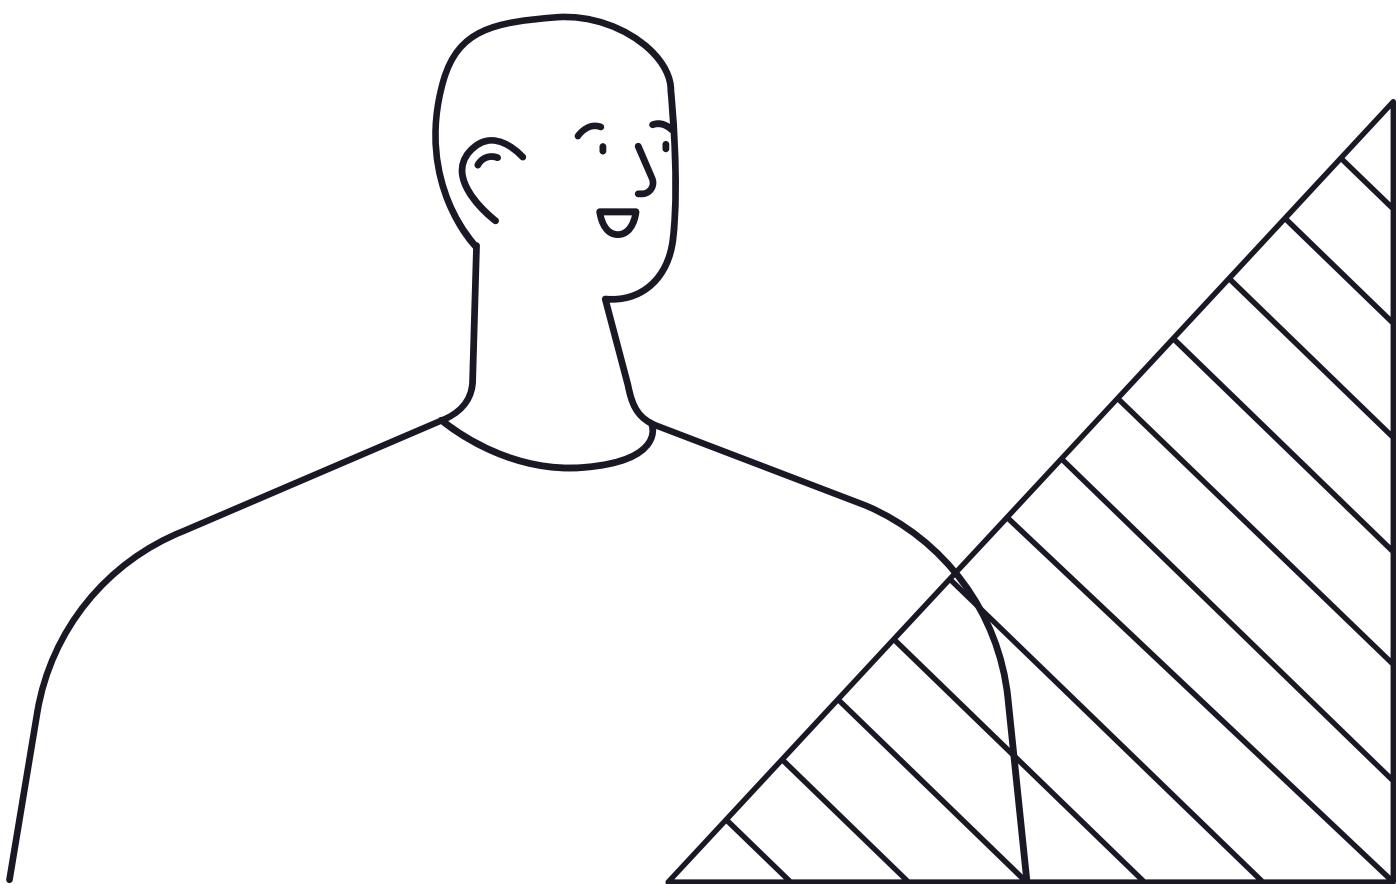
Currently we have materials in English on particle physics and text analysis.

The screenshot shows the homepage of the 'Open data in education' website. The header is dark blue with white text. It features a navigation menu with dropdown arrows and four main sections: 'Materials', 'Open Data', 'Jupyter Notebook Environment', and 'Creating your own material'. Below these is a section titled 'Participate in the Development Work'. At the bottom, there are two buttons: 'Materials on GitHub' with a GitHub icon and 'YouTube channel' with a YouTube icon. A contact section at the very bottom includes an envelope icon and the email address 'avoin-data-apua@cern.ch'. To the right of the main content area, there is a sidebar with a close button ('X') and a large heading 'Welcome to Open D'. The sidebar contains descriptive text about the collection of open data and its purpose, mentioning the Finnish National Agency for Education. There is also a 'Create' button and a 'The mate...' link partially visible.

WEBSITE

ANACONDA

LINKS AND MATERIALS



DATA RESOURCES

- [CERN Open Data Portal](#)
- [Our World In Data](#)
- [Figshare](#)
- [Zenodo](#)
- [World Bank](#)
- [WHO: Global Health Observatory](#).

