

# Introduction to Data Analysis

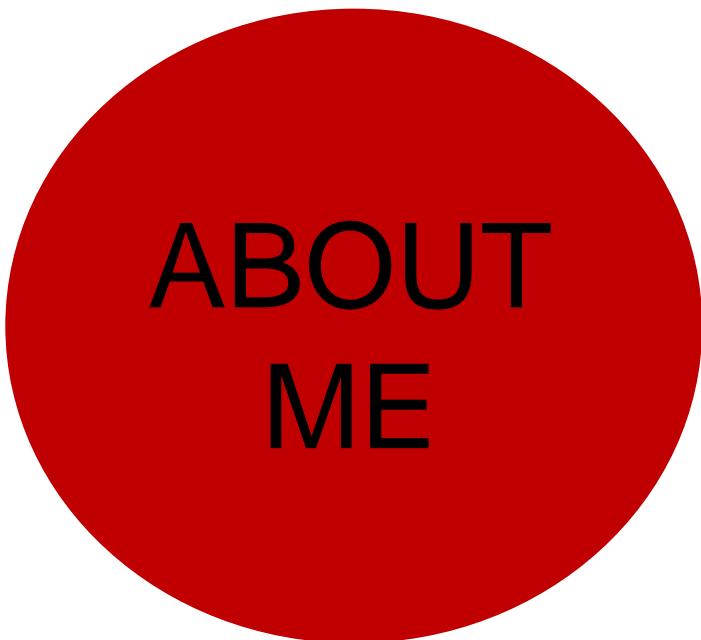
Lecture 1

Thomas S. Woodson

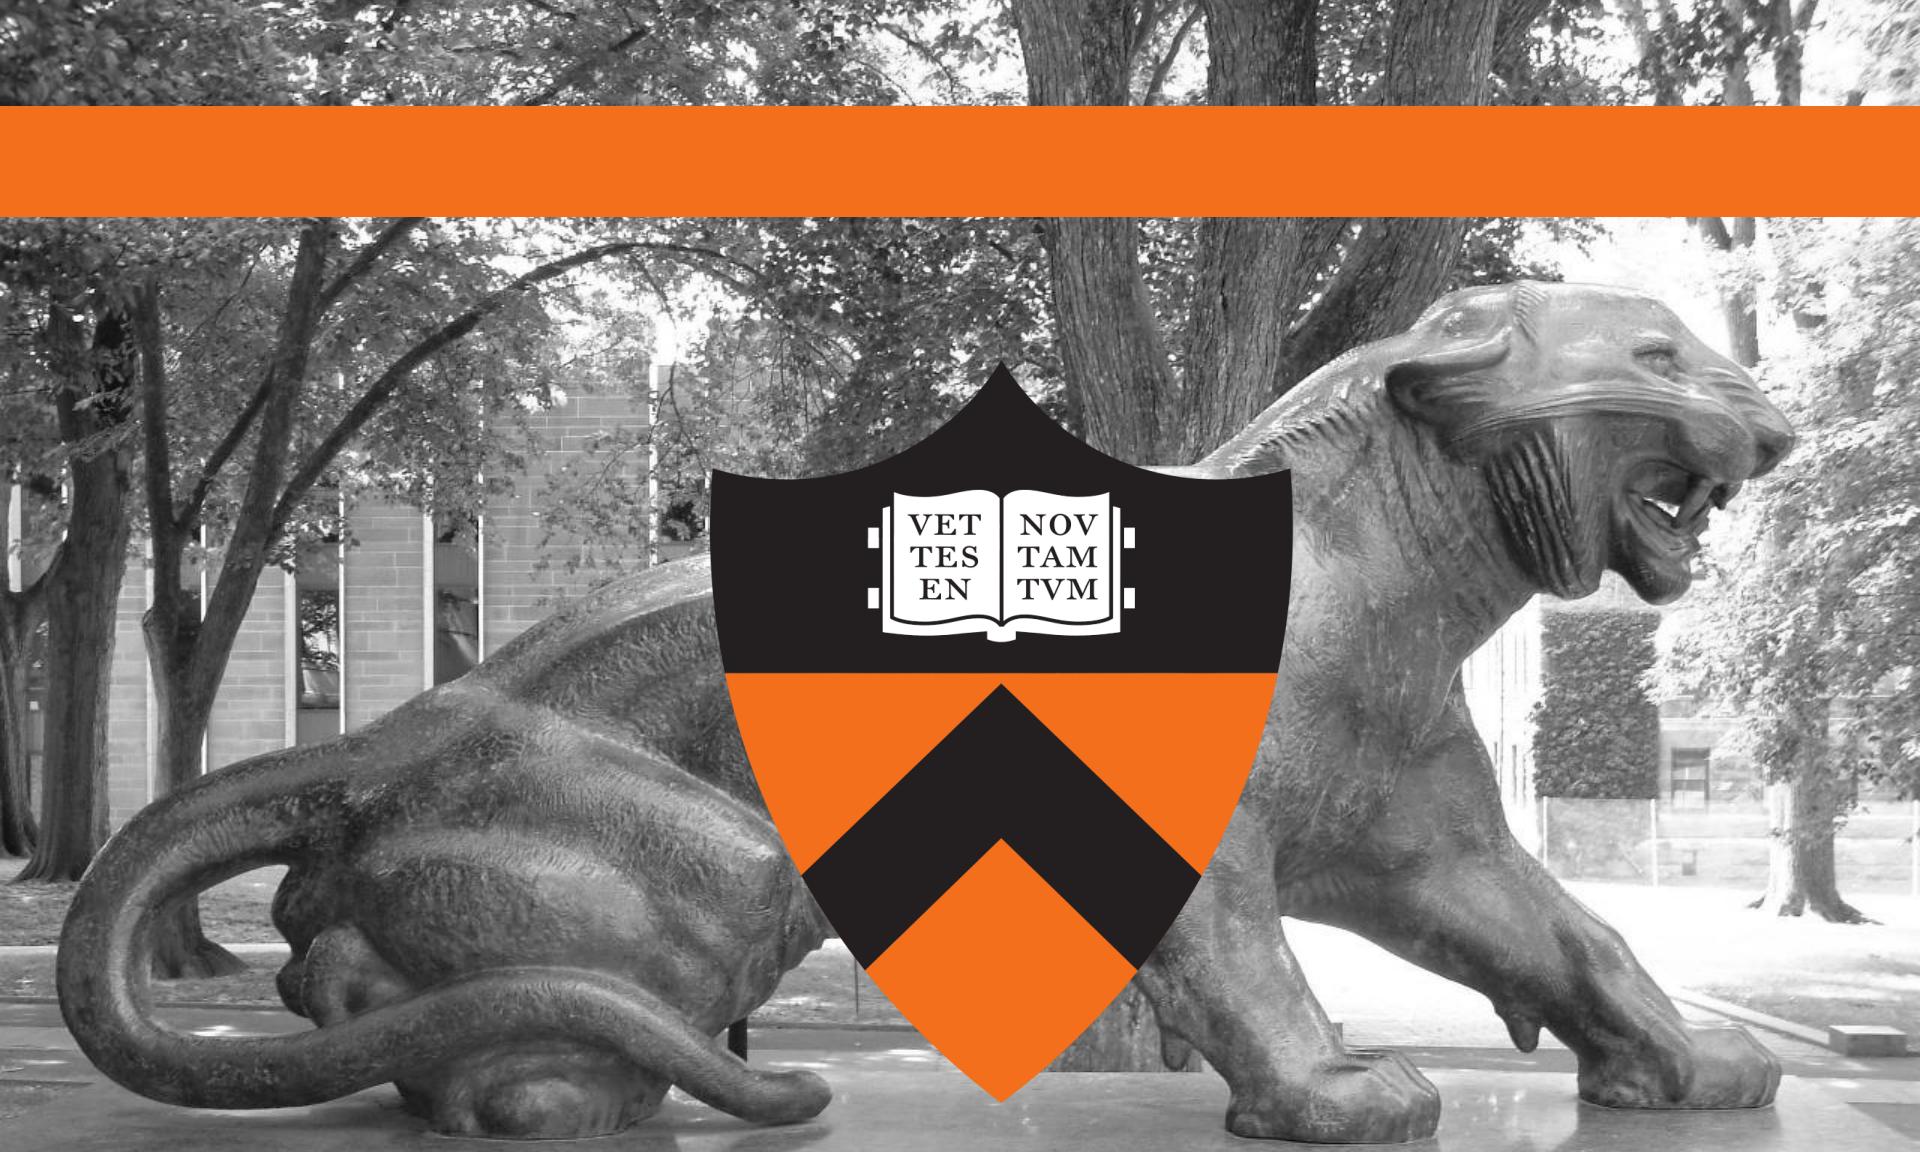
# Exercice d' échauffement:

- Here is a list of exam grades. The highest grade you can get on the exam is 200. How did the students do?
- Did the Master's or PhD students do better?
- Vous trouverez ci-dessous une liste des notes que les étudiants ont reçues lors de l' épreuve finale . La note la plus élevée que vous pouvez obtenir à l'examen est de 200.Comment les étudiants ont-ils réussi?
- Les étudiants de maîtrise ou de doctorat ont-ils fait mieux?

| Grade<br>s | Status |
|------------|--------|
| 140        | PHD    |
| 130        | PHD    |
| 170        | PHD    |
| 100        | PHD    |
| 160        | PHD    |
| 180        | PHD    |
| 120        | PHD    |
| 200        | PHD    |
| 160        | M      |
| 140        | M      |
| 140        | M      |
| 160        | M      |
| 150        | M      |
| 190        | M      |
| 160        | M      |
| 180        | M      |
| 120        | M      |
| 200        | M      |
| 170        | M      |
| 150        | M      |



**ABOUT  
ME**



# Electrical Engineering



PH.D  
Public  
Policy



# Technology and Society

# About Stony Brook



Stony Brook University  
is located only 60 miles  
east of New York City,  
the gateway to the USA

# Department of Technology and Society

- College of Engineering and Applied Sciences
- Bachelors
  - Technological Systems Management
- Master's degree
  - Technological Systems Management
- PhD
  - Technology, Policy and Innovation Policy
- Collège d'ingénieurs et de sciences appliquées
- Les bacheliers
  - Gestion des systèmes technologiques
- Une maîtrise
  - Gestion des systèmes technologiques
- Doctorat
  - Technologie, politique et politique d'innovation



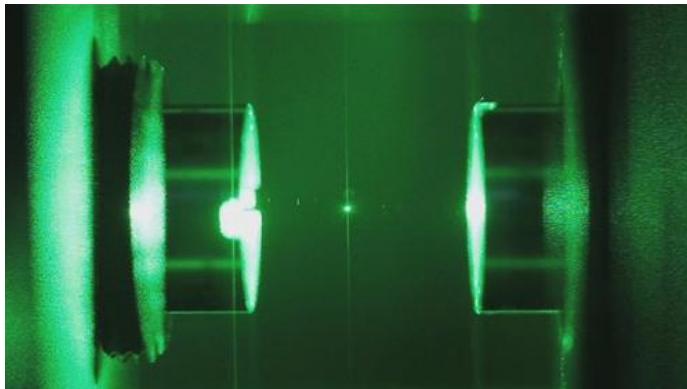
Wolfie the Seawolf

## ENGINEERING

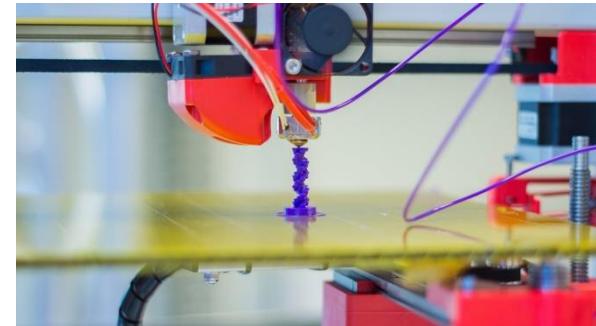


**EDUCATION**

## NANOTECHNOLOGY



## 3D



## PRINTING



## STEM



**DIVERSITY**



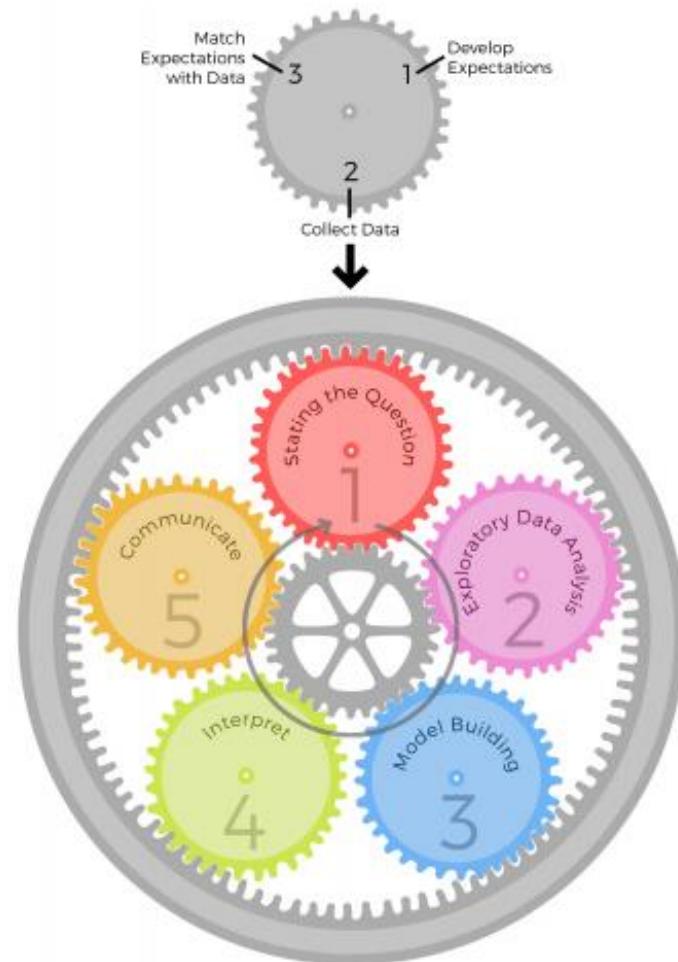
# Qu'est-ce que l'analyse de données (DA)?

Data analysis is sorting and characterizing data to better understand underlying phenomena and predict future events.

L'analyse des données consiste à trier et à caractériser les données pour mieux comprendre les phénomènes sous-jacents et prédire les événements futurs

# Misconceptions about DA

- Data analysis is a not a linear process. **But rather it is an iterative non-linear process.**
- L'analyse des données n'est pas un processus linéaire. **Mais il s'agit plutôt d'un processus itératif non linéaire**



# How to start an analysis

Stating and refining the question.

- Asking the wrong question get the wrong answer.

Collecting and **Exploring and the data**

**Choosing** and building formal models to analyse the data

Interpreting the results

Drawing conclusion and Communicating the results

- Énoncer et affiner la question.
  - Poser la mauvaise question donne la mauvaise réponse.
- La collecte et l' **exploration et les données**
- **Choisir** et construire des modèles formels pour analyser les données
- Interpréter les résultats
- Conclusion et communication des résultats

# What are issues with data?

## Quelles sont les méthodes pour collecter des données?

- Non-response
- Missing values
- Coded incorrectly
- Data entry errors
- Non-réponse
- Valeurs manquantes
- Codé incorrectement
- Erreurs de saisie de données

# Collect Data/ Collecter des données

What are methods to collect data?

- Survey
- Interview
- Measurements from tools
- Census
- Sondage
- Entrevue
- Mesures à partir d'outils
- Recensement

# What is R?

# Qu'est ce que R?

- Statistical computing and graphics language
- Predecessor program, S, was developed by Bell Labs in the 1970s
- Open Source
- Has wide range of applications
- Very powerful and expandable
  - Informatique statistique et langage graphique
  - Programme prédecesseur, S, a été développé par Bell Labs dans les années 1970
  - Open source
  - A une large gamme d'applications
  - Très puissant et extensible

Thomas S. Woodson

# Challenges with R Défis avec R

- No user support call center
- Big learning curve, but very powerful
- Need some programming skills
- If you don't practice R you'll forget
  - Pas de centre d'appel utilisateur
  - Grande courbe d'apprentissage, mais très puissante
  - Besoin de quelques compétences en programmation
  - Si vous ne pratiquez pas R, vous oublierez

Thomas S. Woodson

# Installing R and R Studio

<https://www.r-project.org/>

<https://www.rstudio.com/>

# R Practice

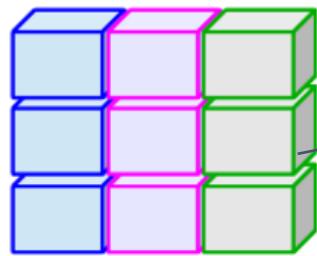
Thomas S. Woodson

# Practice

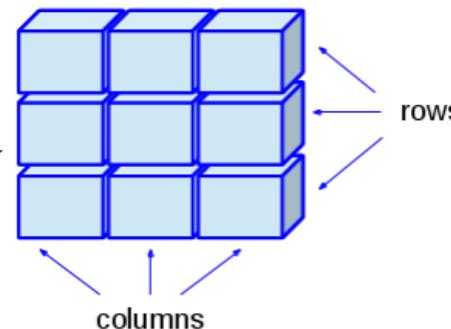
- Create a sequence (2,4,6...20)
- Crée une séquence (2,4,6... 20). Appelle la sequence « seq1 »

# Structure of data(Matrix)

Data Frame  
(Table)



Matrix



$$A = \begin{pmatrix} a_{11} & a_{12} & a_{13} \\ a_{21} & a_{22} & a_{23} \\ a_{31} & a_{32} & a_{33} \end{pmatrix}$$

$a_{jk}$ = jth term (observation) on measurement of kth variable

Rows → Observations  
Columns → Variable

**Rangées → Observations**  
**Colonnes → Variable**

# Descriptive Statistics

What are descriptive statistics? Why do we do it?

**Que sont les statistiques descriptives? Pourquoi le faisons-nous?**

# Descriptive Statistics

## Mean

$$A = \frac{1}{n} \sum_{i=1}^n a_i$$

## Median

“numerical value separating the upper and lower halves of a data vector”

«Valeur numérique séparant les moitiés supérieure et inférieure d'un vecteur de données»

## Mode

“most common value”

«Valeur la plus commune»

# Inferential Statistics

What are inferential statistics?

**Quelles sont les statistiques inférentielles?**

What are the differences?

**Quelles sont les différences?**

# Descriptive/Inferential

Descriptive Statistics : Outlining the nature of the data

Inferential Statistics : Drawing the relationship between sample and population.

Statistiques descriptives: décrivant la nature des données

Statistiques inférentielles: établir la relation entre l'échantillon et la population.

# Variance

Measure of the “spread” of a variable

**Mesure de la «propagation» d'une variable**

$$Var(X) = \frac{1}{n-1} \sum_{i=1}^n (x_i - \mu)^2$$

Variance of sample

Variance de l'échantillon

# Co-Variance

$$cov(x, y) = \frac{\sum(x - \bar{x})(y - \bar{y})}{n}$$

Co-variance measures the linear association between variables.  
The unit of the variables can make a big difference in value

La co-variance mesure l'association linéaire entre les variables.  
L'unité des variables peut faire une grande différence de valeur

# Covariance Matrix

|         | SO2         | temp        | manu        | popul       | wind        | precip       | predays    |
|---------|-------------|-------------|-------------|-------------|-------------|--------------|------------|
| SO2     | 550.947561  | -73.560671  | 8527.7201   | 6711.9945   | 3.1753049   | 15.0017988   | 229.92988  |
| temp    | -73.560671  | 52.239878   | -773.9713   | -262.3496   | -3.6113537  | 32.8629884   | -82.42616  |
| manu    | 8527.720122 | -773.971341 | 317502.8902 | 311718.8140 | 191.5481098 | -215.0199024 | 1968.95976 |
| popul   | 6711.994512 | -262.349634 | 311718.8140 | 335371.8939 | 175.9300610 | -178.0528902 | 645.98598  |
| wind    | 3.175305    | -3.611354   | 191.5481    | 175.9301    | 2.0410244   | -0.2185311   | 6.21439    |
| precip  | 15.001799   | 32.862988   | -215.0199   | -178.0529   | -0.2185311  | 138.5693840  | 154.79290  |
| predays | 229.929878  | -82.426159  | 1968.9598   | 645.9860    | 6.2143902   | 154.7929024  | 702.59024  |

# Correlation coefficient

- Varies from -1 to 1
- Sign indicates direction of association
- Is affected by outliers.
- Varie de -1 à 1
- Le signe indique la direction de l'association
- Est affecté par des valeurs aberrantes.
- $r_{ik} = \frac{s_{ik}}{\sqrt{s_{ii}} * \sqrt{s_{kk}}}$        $r_{ik} = \frac{\sum_{j=1}^n (x_{ji} - \bar{x}_i)(x_{jk} - \bar{x}_k)}{\sqrt{\sum_{i=1}^n (x_{ji} - \bar{x}_i)^2} * \sqrt{\sum_{i=1}^n (x_{jk} - \bar{x}_k)^2}}$

# Correlation Matrix

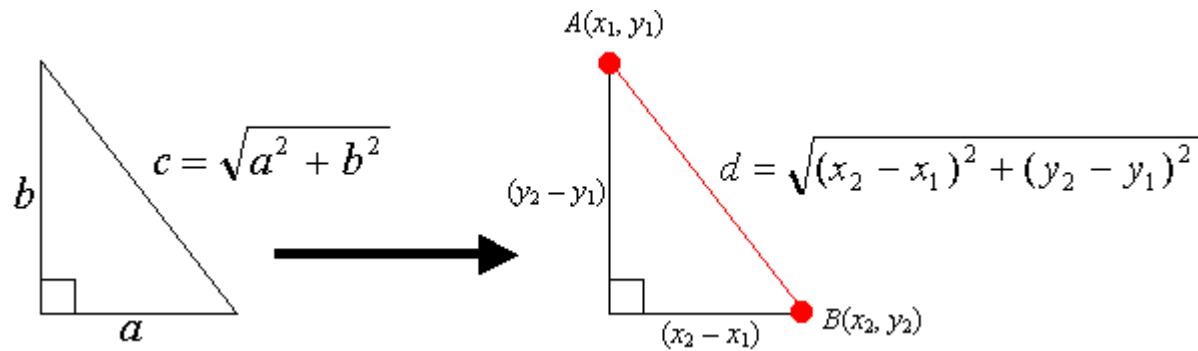
|         | SO2         | temp        | manu        | popul       | wind        | precip      | predays     |
|---------|-------------|-------------|-------------|-------------|-------------|-------------|-------------|
| SO2     | 1.00000000  | -0.43360020 | 0.64476873  | 0.49377958  | 0.09469045  | 0.05429434  | 0.36956363  |
| temp    | -0.43360020 | 1.00000000  | -0.19004216 | -0.06267813 | -0.34973963 | 0.38625342  | -0.43024212 |
| manu    | 0.64476873  | -0.19004216 | 1.00000000  | 0.95526935  | 0.23794683  | -0.03241688 | 0.13182930  |
| popul   | 0.49377958  | -0.06267813 | 0.95526935  | 1.00000000  | 0.21264375  | -0.02611873 | 0.04208319  |
| wind    | 0.09469045  | -0.34973963 | 0.23794683  | 0.21264375  | 1.00000000  | -0.01299438 | 0.16410559  |
| precip  | 0.05429434  | 0.38625342  | -0.03241688 | -0.02611873 | -0.01299438 | 1.00000000  | 0.49609671  |
| predays | 0.36956363  | -0.43024212 | 0.13182930  | 0.04208319  | 0.16410559  | 0.49609671  | 1.00000000  |

# In Class Practice

- Find the mean of the rows
- Find the means of the columns
- Trouver la moyenne des lignes
- Trouver le moyen des colonnes

|    |   |
|----|---|
| 42 | 4 |
| 52 | 5 |
| 48 | 4 |
| 58 | 3 |

# Distance



# Statistical Distance

- **Statistical distance** quantifies the distance between two statistical objects, which can be **two random variables**, or **two probability distributions** or **samples**, or the distance can be between an individual **sample point** and a **population** or a wider sample of points.
- **La distance statistique** quantifie la distance entre deux objets statistiques, qui peuvent être **deux variables aléatoires** , ou **deux distributions de probabilité** ou **échantillons** , ou la distance peut être comprise entre un **point d'échantillonnage** individuel et **une population** ou un échantillon de points plus large.

$$d(Q, P) = \sqrt{\left(\frac{x_1 - y_1}{\sqrt{s_{11}}}\right)^2 + \left(\frac{x_2 - y_2}{\sqrt{s_{22}}}\right)^2} \quad d(O, P) = \sqrt{\left(\frac{x_1}{\sqrt{s_{11}}}\right)^2 + \left(\frac{x_2}{\sqrt{s_{22}}}\right)^2}$$

Distance from Q to P

Thomas S. Woodson