


www.greenplum.com




www.cmu.edu

10. Návrh efektivních vizualizací



www.idvbook.com



www.business2community.com

Efektivní vizualizace

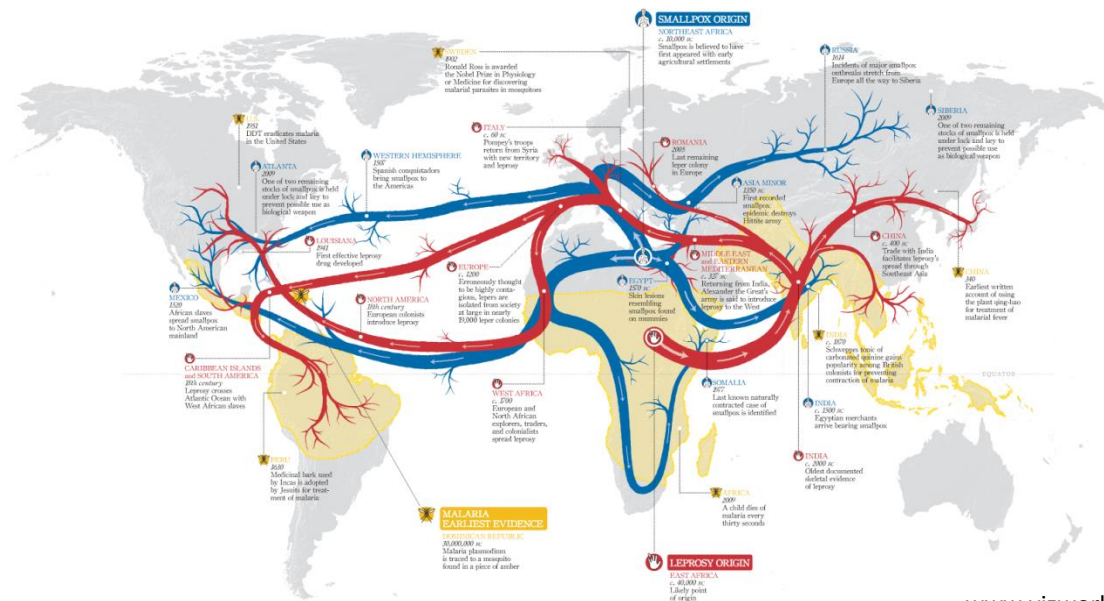
- Úspěšná vizualizace = efektivní a přesné sdělení zamýšlené informace cílovému publiku + účel vizualizace (prozkoumání, potvrzení hypotézy, prezentace, ...)
- Existuje nesčetně mnoho možností pro mapování datových komponent na grafické entity a atributy i celá řada interaktivních nástrojů – nalezení jejich vhodné kombinace není jednoduché

Neefektivní vizualizace

- Příliš matoucí či složité pro interpretaci cílovým publikem
- Nežádoucí deformace, ořezání nebo ztracení dat při mapování
- Nedostatečná podpora interakce – změny pohledu, ovlivnění použité barevné škály, ...
- Zanedbaná estetická složka

Efektivní vizualizace

- Je mnohem jednodušší navrhnout špatnou vizualizaci než kvalitní
- Cílem je tedy poskytnout přehled možných návrhů vizualizace včetně běžných problémů a jejich řešení



A PERIODIC TABLE OF VISUALIZATION METHODS

C continuum																G graphic facilitation						
Tb table	Ca cartesian coordinates																Me meeting trace	Mm metro map	Tm temple	St story template	Tr tree	Ct cartoon
Pi pie chart	L line chart																Co communication diagram	Fp flight plan	Cs concept skeleton	Br bridge	Fu funnel	Ri rich picture
B bar chart	Ac area chart	R radar chart cobweb	Pa parallel coordinates	Hy hyperbolic tree	Cy cycle diagram	T timeline	Ve venn diagram	Mi mindmap	Sq square of oppositions	Cc concentric circles	Ar argument slide	Sw swim lane diagram	Gc gant chart	Pm perspectives diagram	D dilemma diagram	Pr parameter ruler	Kn knowledge map					
Hi histogram	Sc scatterplot	Sa sankey diagram	In information lense	E entity relationship diagram	Pt petri net	Fl flow chart	Cl clustering	Lc layer chart	Py minto pyramid technique	Ce cause-effect chains	Tl toulmin map	Dt decision tree	Cp cpm critical path method	Cf concept fan	Co concept map	Ic iceberg	Lm learning map					
Tk tukey box plot	Sp spectrogram	Da data map	Tp treemap	Cn cone tree	Sy system dyn./simulation	Df data flow diagram	Se semantic network	So soft system modeling	Sn synergy map	Fo force field diagram	Ib ibis argumentation map	Pr process event chains	Pe pert chart	Ev evocative knowledge map	V Vee diagram	Hh heaven 'n' hell chart	I infomural					

Data Visualization
Visual representations of quantitative data in schematic form (either with or without axes)

Information Visualization
The use of interactive visual representations of data to amplify cognition. This means that the data is transformed into an image, it is mapped to screen space. The image can be changed by users as they proceed working with it

Concept Visualization
Methods to elaborate (mostly) qualitative concepts, ideas, plans, and analyses.

Strategy Visualization
The systematic use of complementary visual representations in the analysis, development, formulation, communication, and implementation of strategies in organizations.

Metaphor Visualization
Visual Metaphors position information graphically to organize and structure information. They also convey an insight about the represented information through the key characteristics of the metaphor that is employed

Compound Visualization
The complementary use of different graphic representation formats in one single schema or frame

Process Visualization

Structure Visualization

Overview
 Detail

Detail AND Overview

Divergent thinking
 Convergent thinking


Note: Depending on your location and connection speed it can take some time to load a pop-up picture.
© Ralph Lengler & Martin J. Eppler, www.visual-literacy.org

version 1.5

Su supply demand curve	Pe performance charting	St strategy map	Oc organisation chart	Ho house of quality	Fd feedback diagram	Ft failure tree	Mq magic quadrant	Ld life-cycle diagram	Po porter's five forces	S s-cycle	Sm stakeholder map	Is ishikawa diagram	Tc technology roadmap
Ed edgeworth box	Pf portfolio diagram	Sg strategic game board	Mz mintzberg's organigraph	Z zwickly's morphological box	Ad affinity diagram	De decision discovery diagram	Bm bcg matrix	Stc strategy canvas	Vc value chain	Hy hype-cycle	Sr stakeholder rating map	Ta taps	Sd spray diagram

Periodická tabulka vizualizačních metod

- http://www.visual-literacy.org/periodic_table/periodic_table.html



Hlavní kroky při návrhu vizualizace


1. Rozhodování, jakým způsobem mapovat datová pole na grafické atributy
2. Výběr a implementace metod pro změnu pohledu
3. Výběr množství dat pro vizualizaci
4. Zobrazení doplňkových informací – labels, použité barvy, ...
5. Celková estetika výsledného zobrazení

Intuitivní mapování dat na vizualizaci

- Při vytváření efektivní vizualizace je nutné vzít v úvahu sémantiku dat a kontext typického uživatele
- Výběr vhodného mapování dat na grafické entity, které vyhovuje mentálnímu modelu uživatele
- Čím více je návrhář při předpovídání očekávání uživatele konzistentní, tím je menší riziko dezinterpretace

Intuitivní mapování dat na vizualizaci

- Intuitivní mapování vedou k rychlejší interpretaci



Způsoby mapování


- Nejběžnější je mapování prostorových atributů dat (zeměpisná šířka, délka) na pozice na obrazovce
- První vizualizace využívaly lidskou schopnost určit vztah mezi pozicí vykreslenou na výstupním zařízení a odpovídající pozicí ve 3D světě
- S příchodem animace došlo k intuitivnímu a přirozenému způsobu zobrazení dat měnících se v čase

Způsoby mapování

- Některá mapování jsou intuitivní až ve spojení s příslušným kontextem
 - např. mapování teploty na barvu
- Barva má specifickou interpretaci v mnoha oblastech – kartografie, geologie, ...
- Aplikační doména vizualizace tedy významně ovlivňuje použití barevného atributu

Způsoby mapování

- Jiný způsob reprezentace teploty (v případě, že vyčítáme hodnoty z teploměru) – výška, délka čáry
- Délka často využívána v medicíně – zobrazení krevního tlaku, ...



Výběr způsobu mapování

- Nejdůležitější je kompatibilita mezi škálováním dat a škálováním odpovídajících grafických entit nebo atributů
 - pro uspořádané datové atributy (např. věk) není vhodné použít neuspořádané grafické atributy (tvar)
 - neuspořádané datové atributy (místo narození) není vhodné mapovat na uspořádané grafické atributy (délka)

Výběr způsobu mapování

- V některých případech ale zajímavé prozkoumat data použitím ne zcela intuitivního mapování – odhalení nečekaně zajímavých vlastností dat
- **Pravidlo mapování = co nejintuitivnější nastavení defaultního mapování, aby odpovídalo požadavkům běžného uživatele + umožnění uživateli měnit různá nastavení**

Výběr a modifikace pohledů

- Často je použití jednoho pohledu na data nedostatečné pro prozkoumání všech vlastností a vztahů obsažených v těchto datech
- Klíčem je schopnost odhadnout způsoby pohledů a změn pohledů, které typicky uživatelé používají a poskytnutí intuitivního ovládání a úpravy pohledů na základě požadavků uživatele

Výběr a modifikace pohledů

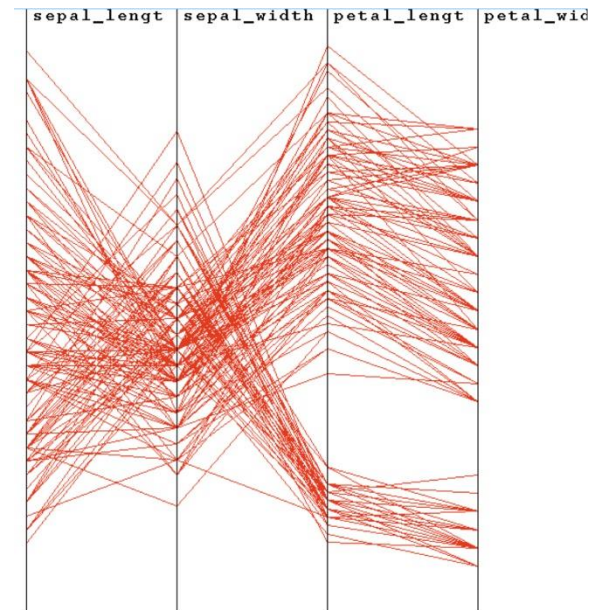

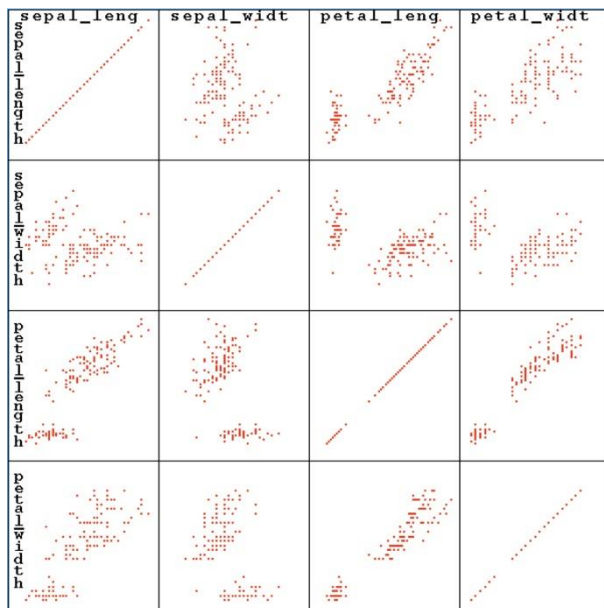
- Každý podporovaný pohled by měl být jasně označen a výběr nového pohledu by měl vyžadovat minimální akce ze strany uživatele
- Změny pohledu spadají do několika kategorií a jejich zahrnutí do základní funkcionality by mělo odrážet priority uživatele
- Tyto kategorie jsou:

Výběr a modifikace pohledů

- **Operace rolování (posouvání) a zoomování** – nutné v případech, kdy nelze celou datovou množinu zobrazit uživateli v požadovaném rozlišení.
- **Modifikace barevné palety** – požadovaná téměř vždy. Minimálně možnost používat různé barevné palety. Dále možnost ovlivňovat jednotlivé barvy nebo celé barevné palety.

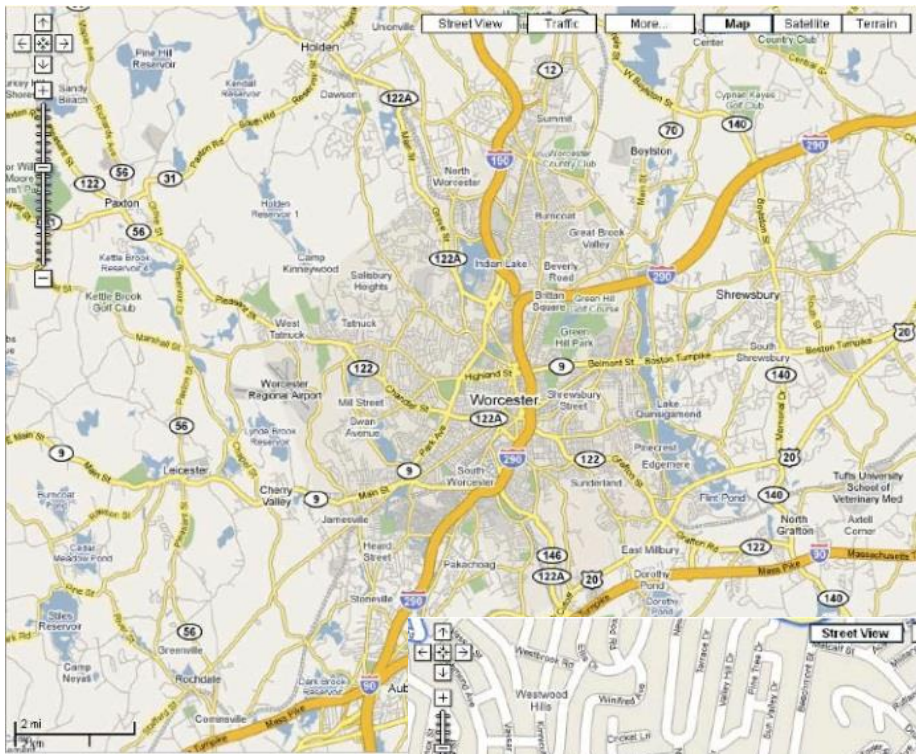
Výběr a modifikace pohledů

- **Modifikace mapování** – umožňuje uživateli přepínat mezi různými způsoby vizualizace stejných dat. Vlastnosti dat, které jsou v jednom mapování skryty, se objeví v jiných.



Výběr a modifikace pohledů

- **Řízení škálování** – dovoluje uživateli modifikovat rozsah a rozložení hodnot příslušného datového pole ještě před jeho mapováním.
- **Řízení level-of-detail** – poskytuje schopnost eliminovat nebo naopak zvýraznit detaily a podporovat pohledy na různých úrovních abstrakce. Možnost přepínat mezi různými úrovněmi (viz obrázek)



Výběr a modifikace pohledů

- Ve všech případech je zásadní, aby manipulace s pohledy byly intuitivní a uživatelsky lehce zapamatovatelné a aby měly vhodně zvolenou přesnost
- Pokud je to možné, je obecně preferována možnost přímé manipulace (změny jsou specifikovány přímo na obrázku)


Hustota informace

- Jedním z klíčových rozhodnutí při návrhu vizualizace je určení, kolik informace zobrazit
- Rozlišujeme dvě extrémní situace:
 1. máme pouze malé množství informace pro zobrazení
 2. snažíme se sdělit příliš mnoho informace

1. Malá hustota informace

- Často rozlišujeme mezi dvěma nebo třemi odlišnými hodnotami

- poměr žen a mužů
- odvození dalších veličin ze základních – např.




zobrazení dvou čísel, jejich součtu a rozdílu

- V těchto případech je efektivnější jednoduše zobrazit tyto kvantitativní hodnoty jako text – šetříme místo na obrazovce

1. Malá hustota informace

Pouze proto, že **můžeme** vizualizace vytvářet, ještě neznamená, že je **musíme** vytvářet!



vs.

23% Female
77% Male

2. Vysoká hustota informace

- Přílišné množství informace může vést ke zmatení a obtížné interpretaci na straně uživatele
- Důležitá informace obsažená v datech může být tímto rozptýlena a uživatel může mít problém s určením, kam zaměřit svoji pozornost


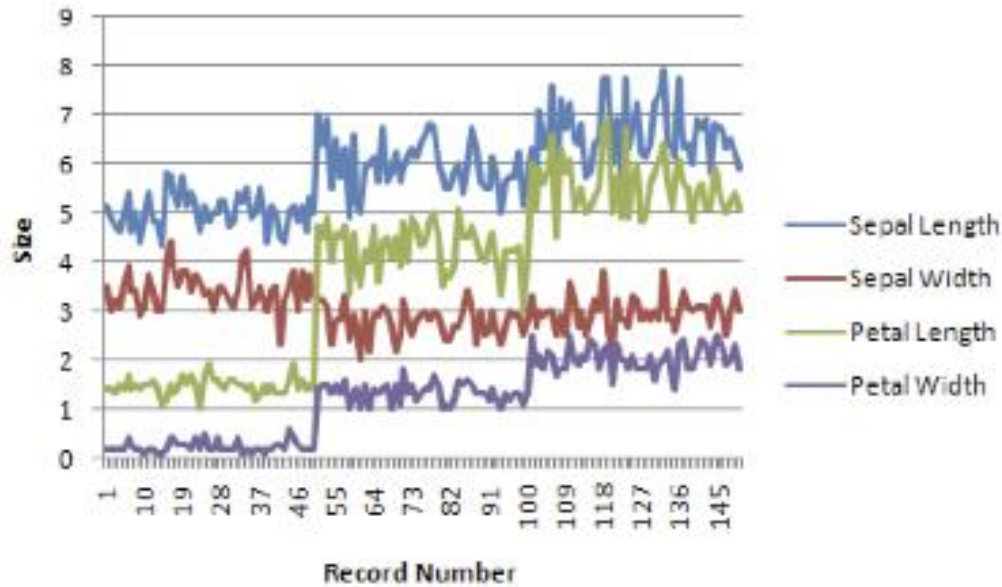
2. Vysoká hustota informace

- Existuje mnoho efektivních řešení:
 - např. uživatel může zobrazovat a skrývat různé komponenty zobrazení – uživatel se často rozhodne, které části jsou pro něj nejdůležitější a ostatní části jsou zobrazeny na požádání
 - využití násobných obrazovek – ve formě disjunktních panelů nebo lze povolit částečné překryvy

Klíče, označení, legendy


- Dalším běžným problémem mnoha vizualizací je neposkytnutí dostatečné doplňkové informace, jejíž přítomnost by zabránila nejednoznačné a nepřesné interpretaci
- Tato dodatečná informace by měla obsahovat detailní popis příslušných zobrazených datových polí
- Pokud jsou použity symboly, musí být poskytnut klíč pro určení jejich významu
- Pokud má i barva svůj význam, musí být přítomna dostatečná informace pro její jednoduchou interpretaci

Klíče, označení, legendy





Klíče, označení, legendy

- Využití značek má svá pozitiva i negativa
- Špatný výběr značek a jejich hustota mohou zastínit samotné zobrazené datové hodnoty





Iris Data



Klíče, označení, legendy



- Samotné pozice označení mají vztah k tomu, jak čitelná bude daná interpretace dat



Klíče, označení, legendy

- Musíme rozhodnout, jaký rozsah hodnot bude zobrazen
- Pokud nezobrazíme samotný rozsah, riskujeme špatnou interpretaci dat
- Např. při práci s procentuálním vyjádřením očekáváme, že zobrazená data jsou v rozsahu 0 – 100. To v mnoha případech vede k plýtvání prostorem obrazovky:

Klíče, označení, legendy



Klíče, označení, legendy

- Při použití **násobných oken** je nutné zachovat konzistentní označení
- Změna pozice označení a klíčů nebo rozsahu zobrazených hodnot pro stejné pole dat může způsobit zmatení a zvyšuje riziko špatné interpretace dat
- Pokud jsou například změny v rozsahu nezbytné, měla by označení tyto změny rovněž reflektovat

Použití barvy

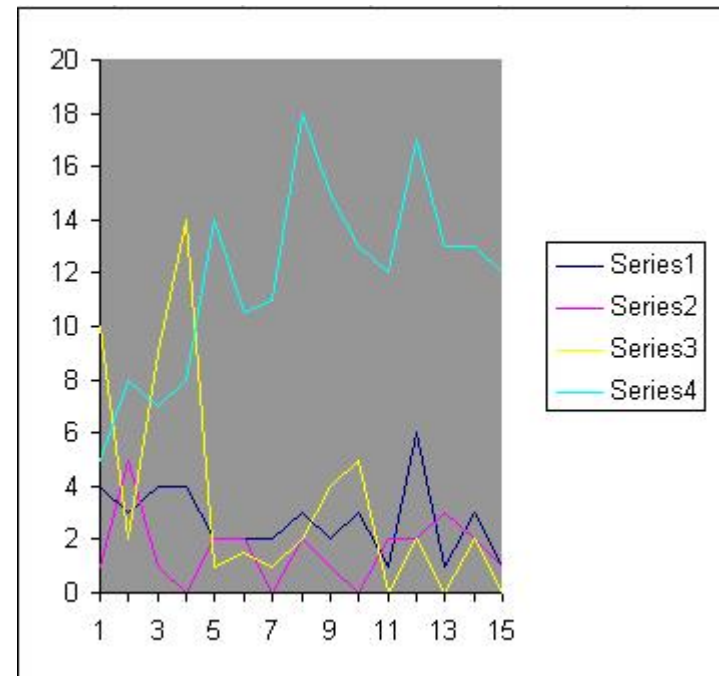
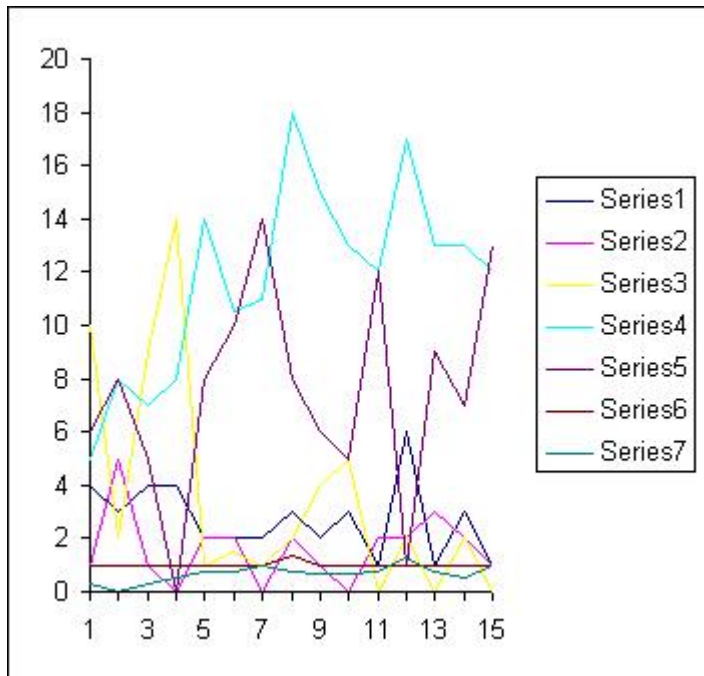
- Jeden z nejčastěji špatně používaných parametrů při návrhu vizualizace je **barva**
- Výběr špatné barevné škály nebo pokus o sdělení přílišného množství kvantitativní informace za použití barvy vede k neefektivní a zavádějící vizualizaci
- Vnímání barvy je navíc závislé na použitém kontextu

Použití barvy

- Musíme mít na paměti, že řada lidí je barvoslepých nebo trpí jinou poruchou vnímání barvy (až 10% mužů)
- Následující pravidla mohou pomoci při návrhu efektivního využití barvy ve vizualizaci:

Použití barvy

1. Pokud daný vizualizační úkol vyžaduje absolutní rozhodnutí, měli bychom použít pouze omezený počet různých numerických úrovní





Použití barvy

2. Pokud je to možné, využívat redundantní mapování, například mapování určitého pole dat na barvu a velikost zároveň

Atlantic Division													Central Division													
Boston Celtics													Atlanta Hawks													
And	Bat	B B	Ca		Pal	Pierce			Pota	Stith	Walker	Will	B Cra	Glo	Hender	Jo	Kukoc	Mal	Mohan	M Rob	S Terry	Wright				
Miami Heat													Charlotte Hornets													
Bo	Car	Ceb	D	Grant	G	Hardawa	H Jones			M	Mason	Mourni	Brow	Bur	Campbell	Cole	Davis	M	Mashburn	N	R. Robi	Wesley				
New Jersey Nets													Chicago Bulls													
D	F Gill	G	Hari	Jack	Maibury		Marti	New	O	St	Van Horn	Willia	Artest	Be	Brand		Cr Dre	El-	Fizer	Gu	Hoibe	Mercer	Miller			
New York Knicks													Cleveland Cavaliers													
Canby	Hari	Houston		Jack	Johns		Ruce			Sprewell	Thoma	War	B C	Gatlin	Harpri	H	Ilgauk	Jacks	Kn	La	Mih	Miller	Murray	Per	Tr	Weathe
Orlando Magic													Detroit Pistons													
Am	Armstrong	Bro	D Do	Garr	Hill		H	McGrady		Miller	Out	Wi	Atkins	Barro	B	Cle	Cu	M O	Smuth	Stackhouse		Wal	Wal	Williamson		

Použití barvy

3. Při vytváření barevných map pro reprezentaci numerické informace se musíme ujistit, že pro každý záznam je změněna barva i její sytost



Použití barvy

4. Zahrnout klíč určující, jakým způsobem jsou barvy namapovány na data – pomáhá interpretaci barvy
- Barva může vizualizaci přidat významnou vizuální působivost, ale může naopak i významně snížit efektivitu celého komunikačního procesu
 - Někteří návrháři preferují při iniciálním návrhu využití pouze šedotónních odstínů
 - Přidání barvy až po otestování prvotního návrhu může být provedeno mnohem efektivněji

Důležitost estetiky

- Nakonec musíme zhodnotit estetickou stránku návrhu
- Nejlepší vizualizace jsou jak informativní, tak vizuálně přitažlivé
- Na opačném pólu stojí vizualizace, které jsou tak vizuálně nehezké, že přímo odrážejí od komunikačního procesu
- Vizuálně přitažlivé vizualizace naopak lákají uživatele prozkoumat data více do hloubky



Důležitost estetiky

- Existuje řada pravidel pro návrh atraktivních vizualizací:
 - Focus (zaměření)
 - Balance (vyváženost)
 - Simplicity (jednoduchost)




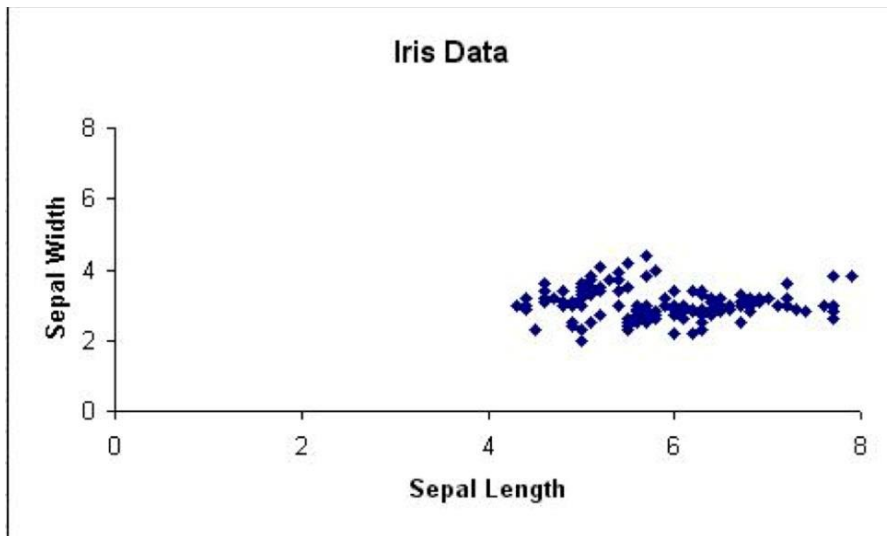
Focus

- Uživatel by měl být směřován na tu část vizualizace, která je nejdůležitější



Balance

- Prostor obrazovky by měl být využit efektivně, nejdůležitější komponenty by měly být umístěny do středu

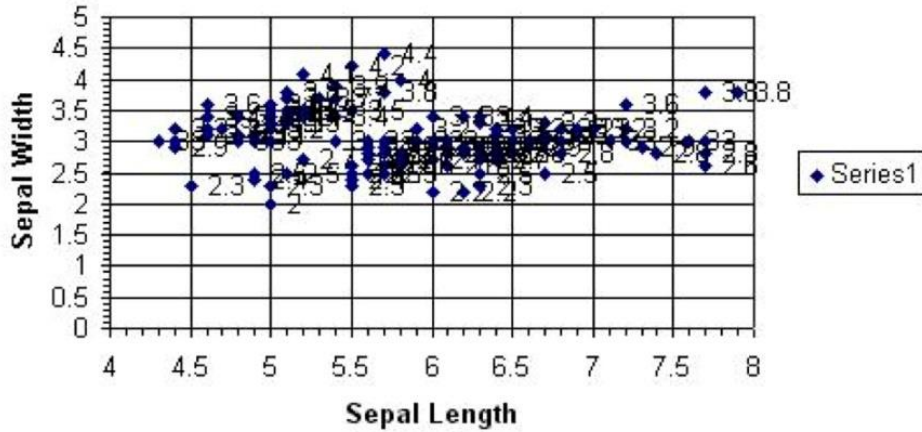


Simplicity


- Hlavním pravidlem je nesnažit se nahustit co nejvíce informace na jednu obrazovku a nepoužívat různé grafické triky jenom proto, že jsou dostupné
 - například nepoužívat histogramy s 3D Phongovým stínováním, když tu stejnou informaci jednoduše sdělíme pomocí bodového nebo čárového grafu
- Běžná procedura pro eliminaci těchto „chyb“ u již navržených vizualizací je založena na iterativním odstraňování vlastností a poté měření velikosti ztráty sdělované informace

Simplicity


Iris Data



Iris Data

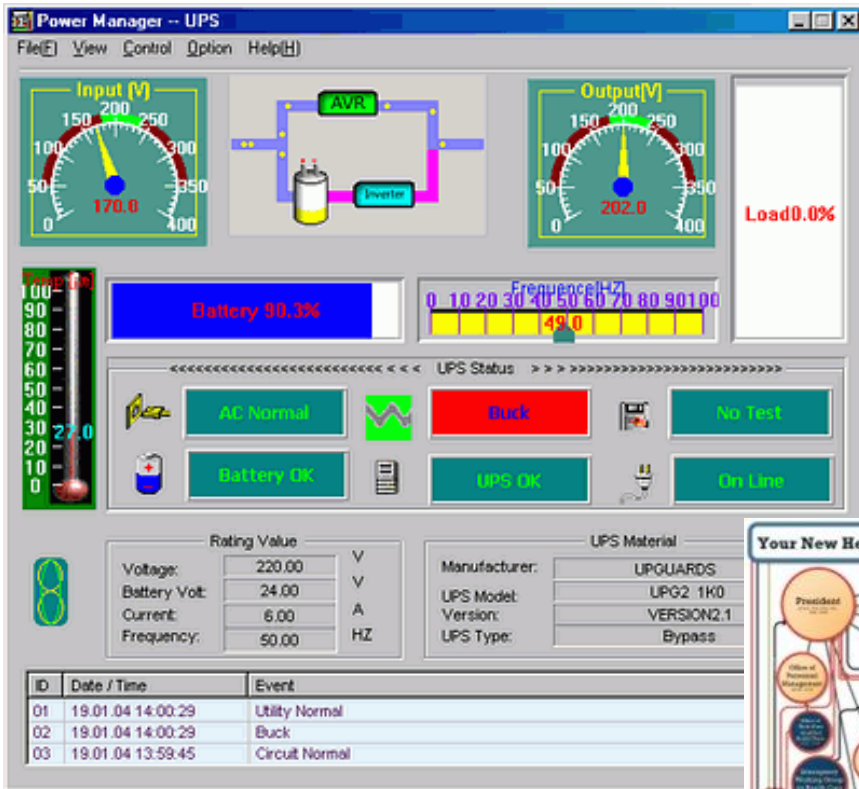


Iris Data

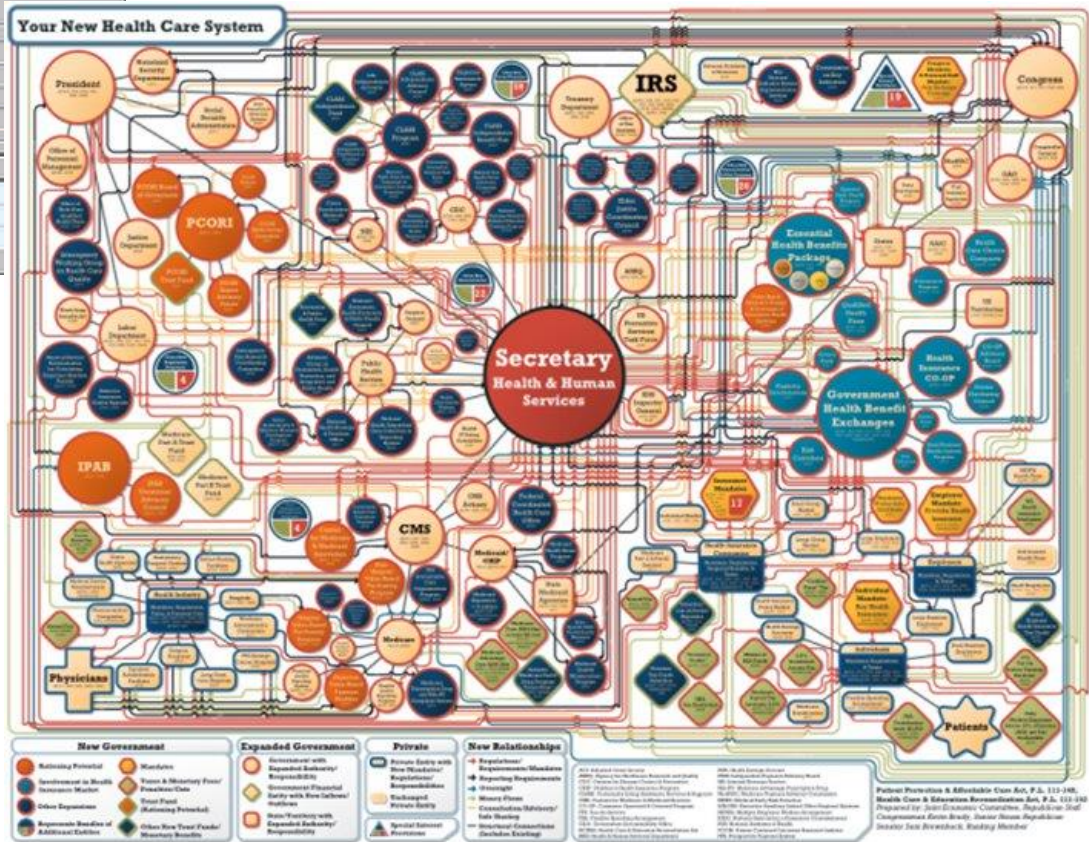


Důležitost estetiky

- V literatuře nalezneme mnoho příkladů „ošklivých“ vizualizací (viz další slide)
- Po provedení návrhu vizualizace je vřele doporučováno nechat si výsledek esteticky zhodnotit, než bude prezentován uživatelům





www.cs.ubc.ca



www.seo.com

Důležitost estetiky



Problémy při návrhu efektivních vizualizací

- Zaměříme se na prozkoumání některých běžných problémů vyskytujících se při vizualizacích, které se mohou objevit, i když dodržujeme předchozí uvedená pravidla
- Tyto problémy mají hlubší kořeny a souvisí s rozhodnutím, co vlastně vizualizovat a jaká je pro to nejvhodnější metoda

Zavádějící vizualizace



- Jedním z hlavních pravidel při vizualizaci je skutečnost, že obrázek by měl přesně znázorňovat požadovaná data
- V historii je mnoho příkladů, kdy deformovaná vizualizace dat dokázala změnit názor uživatelů a v podstatě jim lhát – „**viz lies**“
- Podíváme na některé běžné strategie používané pro vytváření zavádějících vizualizací - abychom se jim mohli v budoucnu vyhnout

Zavádějící vizualizace

- **Data scrubbing**

- Surová data mohou být často velmi hrubá, a proto jsme při návrhu vizualizace často v pokušení tuto hrubost odstranit
- Výběr může být proveden tak nešťastně, že po eliminaci dat objevím vztahy, které v původních datech vůbec nebyly (viz obrázek další slide)

Zavádějící vizualizace



Zavádějící vizualizace

- Běžnou taktikou používanou v této situaci je odstranění významně se odlišujících hodnot (outliers)
- I když je oprávněný důvod věřit, že tyto odlišné hodnoty vznikly díky chybám při procesu získávání dat, neměly by být odstraněny bez toho, aniž bychom o tom uživatele informovali


Zavádějící vizualizace

- **Unbalanced scaling**

- Škálování je velmi silným nástrojem používaným při vizualizaci, protože pečlivý výběr škálovacích faktorů může odhalit vzory a struktury, které nejsou v neškálovaných datech viditelné
- Škálování může být použito i k oklamání pozorovatele, který pak věří, že daný trend v datech je silnější nebo slabší, než je ve skutečnosti = tzv. „**lie factor**“ (poměr mezi změnou v surových datech a změnou znázorněnou pomocí vizualizace)

Zavádějící vizualizace

- Velikost (šířka i výška) objektů v pozadí je redukována s perspektivou, čímž narušujeme možnost jejich porovnání s objekty vepředu




Zavádějící vizualizace

- **Range distortion**

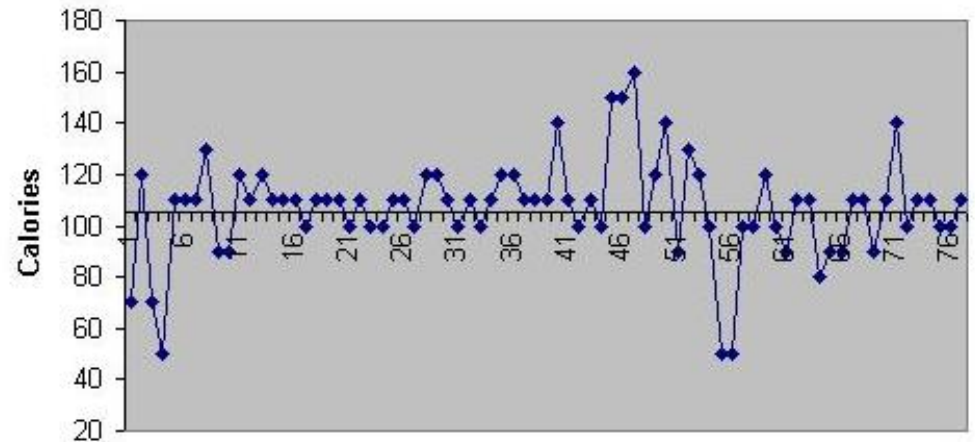
- Uživatelé často mají jistá očekávání týkající se rozsahu hodnot v příslušné dimenzi
- Nastavení rozsahu zcela odlišného od tohoto očekávání může opět vést k dezinterpretaci
- Častým příkladem je posun osy takovým způsobem, že už dále nekoresponduje s očekávanou nulovou hodnotou (viz obrázek další slide)

Zavádějící vizualizace

Breakfast Cereal Calories



Breakfast Cereal Calories



Zavádějící vizualizace

- **Abusing dimensionality**


- Počet chyb v interpretaci je úměrný mocnině počtu dimenzí zobrazovaných dat
- Naše chybovost při posuzování objemu je mnohem vyšší než při posuzování plochy a ta je vyšší než při posuzování délky
- Mapování skalární hodnoty na grafický atribut objem tedy významně zvyšuje pravděpodobnost chybné interpretace
- I zde platí pravidlo: **čím jednodušší, tím lepší**

Vizuální nesmysly

- Vizualizace jsou vytvářeny pro sdělení informace a je důležité, aby tato informace byla smysluplná
- Vizualizace jsou často vytvářeny kombinováním datových sad pocházejících z různých zdrojů
- Je jednoduché kombinovat nesouvisející komponenty do jedné vizualizace a identifikovat v nich strukturu

Vizuální nesmysly

- Vykreslení hodnot na burze proti výskytu skvrn na Slunci




Vizuální nesmysly

- Při rozhodování, která data kombinovat, je důležité se nejdříve ujistit, že je v jejich kombinaci určitá logika
- Další faktor, který musíme vzít v úvahu, je kompatibilita mezi časovými a prostorovými rozsahy porovnávaných dat
- Při vytváření datových sad pro vizualizaci musíme vzít v úvahu i kompatibilitu jednotek


Vizuální nesmysly

- Často jsme v pokušení aplikovat operace, které jsou vhodné pro uspořádaná nebo spojitá data, na kategorická, neuspořádaná data – jednoduše protože výsledkem mapování byla uspořádaná grafická reprezentace



Ztráta dat díky Chart Junk

- **Chart Junk** = veškeré vizuální prvky v grafech a diagramech, které nejsou nezbytné pro pochopení informace prezentované v grafu a spíše rozptylují pozornost uživatele



Ztráta dat díky Chart Junk

- Tato doplňková informace může vést nejen k přehnaně složitým vizualizacím, ale rovněž k okluzi a zeslabování vizuální reprezentace původních dat
- Rozhodnutí, jaké množství doplňkové grafiky použít, je často obtížný proces
- Pracujeme s dynamickým a uživatelsky měnitelným médiem, můžeme tedy uživateli umožnit ovlivňovat míru zobrazení těchto doplňkových informací

Ztráta dat díky Chart Junk

- V některých vizualizačních úkolech může uživatel přepínat mezi kvalitativním náhledem a kvantitativní analýzou
- V prvním případě je obvykle důležitější poskytnout uživateli čistý pohled na data, zatímco ve druhém případě jsou žádoucí doplňkové nástroje, které pomáhají kvantifikovat zobrazené prvky

Ztráta dat díky Chart Junk

- **Pravidlo:**

Poskytnout dostatečné nástroje pro podporu kvantitativních náhledů a zároveň umožnit jejich odstranění nebo změnu stupně jejich zapojení do vizualizace



Surová vs. odvozená data

- Běžnou praktikou při snaze o dosažení co nejlepšího vizuálního výsledku je spočtení analytického modelu dat reprezentovaného křivkami či povrchem
- Tato technika může opět vést ke zkreslení a ve výsledku ke špatným předpokladům a odvozeným závěrům

Surová vs. odvozená data

- V některých vizualizacích je běžnou praktikou odstranit všechna surová data a nahradit je hladkou aproximací odvozenou z těchto dat
- Uživatel pak musí věřit, že daná aproximace je přesným zobrazením dat, což často není pravda
- Nejvhodnější je v tomto případě zobrazit jak surová data, tak jejich aproximaci, a umožnit uživateli si tyto typy filtrovat na požádání

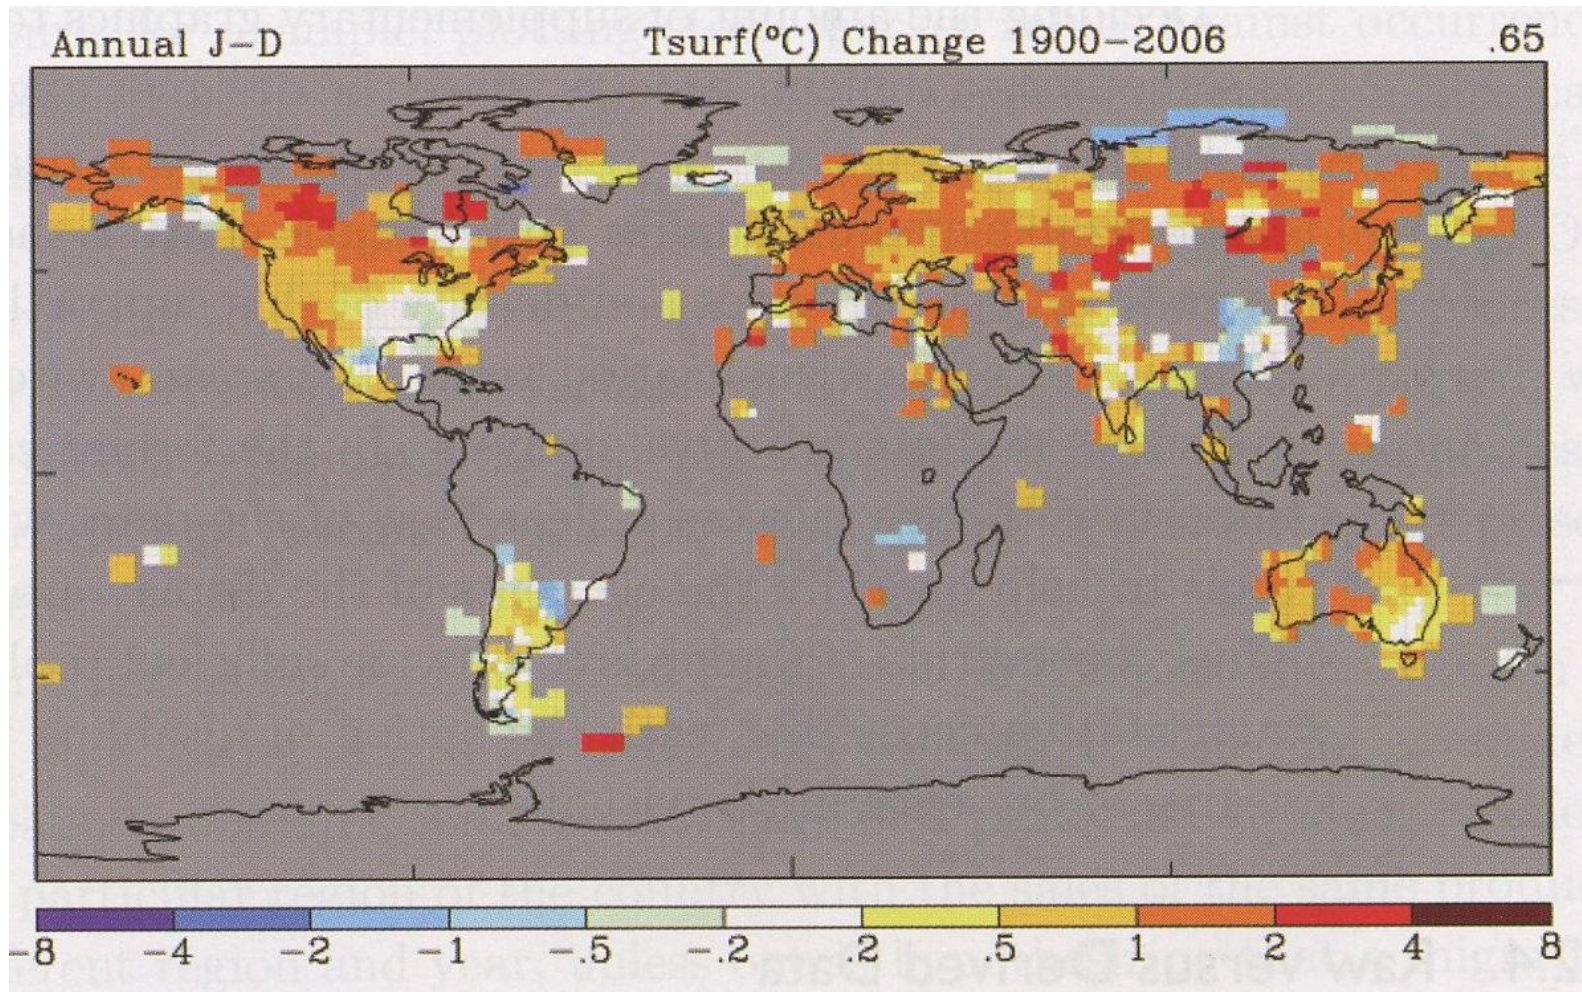
Surová vs. odvozená data



Surová vs. odvozená data


- Další formou „čištění“ dat je proces **převzorkování**, kdy jsou surová data umístěná náhodně nebo v řídké mřížce použita pro vytvoření mnohem hustší mřížky
- To vede k mnohem bohatším vizualizacím, které se blíží spojitému vzorkování, opět ale klameme uživatele
- Čím hustší převzorkování, tím větší pravděpodobnost špatné interpretace dat

Surová vs. odvozená data



Surová vs. odvozená data

- Dalším problémem je nedostatečné vzorkování:



Surová vs. odvozená data

- Je nutné, aby měl uživatel vždy přístup k surovým datům a aby byl informován o jakékoliv operaci vyhlazení či převzorkování, která byla na data aplikována
- V některých oborech, jako například v radiologii, jsou analytici zásadně proti použití jakéhokoliv vyhlazení či filtrování, protože je nebezpečí, že důležitý signál by mohl být vyhodnocen jako šum
- Proto je vhodné poskytnout uživateli pohled na surová data i na odvozená a nechat je rozhodnout, zda dané odvození dostatečně reprezentuje původní data

Zajímavé odkazy

- Four Pillars of Effective Visualizations

<http://www.youtube.com/watch?v=nrsdgvauqKg>

- Designing Data Visualizations

<http://www.youtube.com/watch?v=ITAeMU2XI4U>

- Designing Data Visualizations with Noah Iliinsky

<http://www.youtube.com/watch?v=R-oiKt7bUU8>