
역사 데이터 시각화 분석

Correlation Analysis with R

What is Correlation Analysis?

Correlations are useful because they can indicate a predictive relationship that can be exploited in practice

● 개념(Concept)

- 두 변수나 두 데이터 세트 사이에 존재하는 선형관계의 정도를 파악하는 분석이다.
- R(상관계수)값을 이용한다.
- 상관계수의 값이 -1이면 완전한 음의 상관이고, +1이면 완전한 양의 상관이다.
- 음의 상관관계가 있는 두 변수를 산점도로 나타내면 점의 분포는 우 하향의 모습을 띠고 양의 상관관계가 있는 두 변수를 산점도로 나타내면 점의 분포는 우 상향의 모습을 띤다.
- 상관계수는 $-1 < R < 1$ 의 범위 값을 지닌다.

● 수식(Formula)

$$r_{xy} = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{(n-1)s_x s_y} = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2 \sum_{i=1}^n (y_i - \bar{y})^2}},$$

What is Correlation Analysis?

Correlations are useful because they can indicate a predictive relationship that can be exploited in practice

- 상관관계가 유의하지 않은 경우

- 이상치(outlier)가 존재하는 경우, 이 값은 상관계수 값에 큰 영향을 미치므로 이상치의 존재 여부를 확인한 후 상관 분석을 시행하여야 한다.
- 두 변수의 관계가 비선형인 경우 상관계수는 유의하지 않다.
- 상관계수의 값을 통해 얻어진 결과는 상호간에 상관관계가 있는 것이지, 절대적인 인과관계가 있다고 해석하는 것은 오류이다.

Correlation Analysis with R

● 예제(Example)

- mtcars 데이터 셋은 데이터는 1974년 모터 트렌드 미국 잡지에서 추출하였으며 1973년-1974년도 모델의 32종의 자동차들의 연비등 자동차의 11가지 중요 정보를 나타내고 있다.

● 변수 설명

- mpg = 마일 / (US) 갤런
- cyl = 실린더의 수
- disp = 변위 (cu.in.)
- hp = 총 마력
- drat = 리어 액슬 비율
- wt = 무게 (파운드 / 1000)
- qsec = 1/4 마일 시간
- vs = V / S
- am = 변속기 (0 = 자동, 1 = 수동)
- gear = 기어의 수
- carb = 기화기의 수

```
> str(mtcars)
'data.frame': 32 obs. of 12 variables:
 $ X    : Factor w/ 32 levels "AMC Javelin",...: 18 19 5 13 14 31 7 21 20 22 ...
 $ mpg : num  21 21 22.8 21.4 18.7 18.1 14.3 24.4 22.8 19.2 ...
 $ cyl  : int  6 6 4 6 8 6 8 4 4 6 ...
 $ disp : num  160 160 108 258 360 ...
 $ hp   : int  110 110 93 110 175 105 245 62 95 123 ...
 $ drat: num  3.9 3.9 3.85 3.08 3.15 2.76 3.21 3.69 3.92 3.92 ...
 $ wt   : num  2.62 2.88 2.32 3.21 3.44 ...
 $ qsec: num  16.5 17 18.6 19.4 17 ...
 $ vs   : int  0 0 1 1 0 1 0 1 1 1 ...
 $ am   : int  1 1 1 0 0 0 0 0 0 ...
 $ gear: int  4 4 4 3 3 3 3 4 4 4 ...
 $ carb: int  4 4 1 1 2 1 4 2 2 4 ...
```

Correlation Analysis with R

● 데이터 확인

```
> str(mtcars)
```

```
'data.frame': 32 obs. of 12 variables:  
 $ X    : Factor w/ 32 levels "AMC Javelin",...: 18 19 5 13 14 31 7 21 20 22 ...  
 $ mpg  : num  21 21 22.8 21.4 18.7 18.1 14.3 24.4 22.8 19.2 ...  
 $ cyl   : int  6 6 4 6 8 6 8 4 4 6 ...  
 $ disp  : num  160 160 108 258 360 ...  
 $ hp    : int  110 110 93 110 175 105 245 62 95 123 ...  
 $ drat  : num  3.9 3.9 3.85 3.08 3.15 2.76 3.21 3.69 3.92 3.92 ...  
 $ wt    : num  2.62 2.88 2.32 3.21 3.44 ...  
 $ qsec  : num  16.5 17 18.6 19.4 17 ...  
 $ vs    : int  0 0 1 1 0 1 0 1 1 1 ...  
 $ am    : int  1 1 1 0 0 0 0 0 0 0 ...  
 $ gear  : int  4 4 4 3 3 3 3 4 4 4 ...  
 $ carb  : int  4 4 1 1 2 1 4 2 2 4 ...
```

```
> head(mtcars)
```

	X	mpg	cyl	disp	hp	drat	wt	qsec	vs	am	gear	carb
1	Mazda RX4	21.0	6	160	110	3.90	2.620	16.46	0	1	4	4
2	Mazda RX4 Wag	21.0	6	160	110	3.90	2.875	17.02	0	1	4	4
3	Datsun 710	22.8	4	108	93	3.85	2.320	18.61	1	1	4	1
4	Hornet 4 Drive	21.4	6	258	110	3.08	3.215	19.44	1	0	3	1
5	Hornet Sportabout	18.7	8	360	175	3.15	3.440	17.02	0	0	3	2
6	Valiant	18.1	6	225	105	2.76	3.460	20.22	1	0	3	1

- 전체 데이터를 요약함으로써 각 변수의 데이터 특징을 한눈에 파악할 수 있다.

Correlation Analysis with R

● 상관분석

- Pearson상관계수: 데이터가 연속형 변수(등간척도, 비율척도)일때 사용하며, 확률분포로 정규분포를 가정한다.
- Kendall상관계수: 데이터가 질적 변수(순위척도)일때 사용하며, 확률분포에 대한 가정이 없고 비모수적 방법의 상관분석이다.

● 변수 mpg와 cyl간의 상관분석

```
> attach(mtcars)
> cor(mpg,cyl,method="pearson")
[1] -0.852162
> cor(mpg,cyl,method="kendall")
[1] -0.7953134
> cor.test(mpg,cyl)

Pearson's product-moment correlation

data: mpg and cyl
t = -8.9197, df = 30, p-value = 6.113e-10
alternative hypothesis: true correlation is not equal to 0
95 percent confidence interval:
-0.9257694 -0.7163171
sample estimates:
cor
-0.852162

> detach(mtcars)
```

- mpg와 cyl에 대해 상관분석을 한 결과 p값이 0.05이하 이므로 두 변수간 연관성이 있다는 결과가 나왔다.

● 상관 계수 값 계산하기

```
> sum((mpg-mean(mpg))*(cyl-mean(cyl)))/sqrt(sum((mpg-mean(mpg))*(mpg-mean(mpg)))*sum((cyl-mean(cyl))*(cyl-mean(cyl))))
[1] -0.852162
```

Correlation Analysis with R

● 상관행렬 생성하기

```
> mtcars_2<-mtcars[,2:12]
> head(mtcars_2)
  mpg cyl disp hp drat wt qsec vs am gear carb
1 21.0   6 160 110 3.90 2.620 16.46 0 1 4 4
2 21.0   6 160 110 3.90 2.875 17.02 0 1 4 4
3 22.8   4 108 93 3.85 2.320 18.61 1 1 4 1
4 21.4   6 258 110 3.08 3.215 19.44 1 0 3 1
5 18.7   8 360 175 3.15 3.440 17.02 0 0 3 2
6 18.1   6 225 105 2.76 3.460 20.22 1 0 3 1
> mcov<-cor(mtcars_2)
> round(mcov,2)
      mpg cyl disp hp drat wt qsec vs am gear carb
mpg  1.00 -0.85 -0.85 -0.78  0.68 -0.87  0.42  0.66  0.60  0.48 -0.55
cyl  -0.85  1.00  0.90  0.83 -0.70  0.78 -0.59 -0.81 -0.52 -0.49  0.53
disp -0.85  0.90  1.00  0.79 -0.71  0.89 -0.43 -0.71 -0.59 -0.56  0.39
hp   -0.78  0.83  0.79  1.00 -0.45  0.66 -0.71 -0.72 -0.24 -0.13  0.75
drat  0.68 -0.70 -0.71 -0.45  1.00 -0.71  0.09  0.44  0.71  0.70 -0.09
wt   -0.87  0.78  0.89  0.66 -0.71  1.00 -0.17 -0.55 -0.69 -0.58  0.43
qsec  0.42 -0.59 -0.43 -0.71  0.09 -0.17  1.00  0.74 -0.23 -0.21 -0.66
vs    0.66 -0.81 -0.71 -0.72  0.44 -0.55  0.74  1.00  0.17  0.21 -0.57
am    0.60 -0.52 -0.59 -0.24  0.71 -0.69 -0.23  0.17  1.00  0.79  0.06
gear  0.48 -0.49 -0.56 -0.13  0.70 -0.58 -0.21  0.21  0.79  1.00  0.27
carb -0.55  0.53  0.39  0.75 -0.09  0.43 -0.66 -0.57  0.06  0.27  1.00
```

- 각각의 변수에 대하여 Pearson 상관계수 행렬을 생성하면 변수들간의 상관관계를 한눈에 파악 할 수 있다.

Correlation Analysis with R

- 상관계수 행렬 값을 활용한 히트 맵(Hitmap)

```
> install.packages("corrplot")
URL 'http://cran.rstudio.com/bin/macosx/contrib/3.1/corrplot_0.73.tgz'을 시도합니다
Content type 'application/x-gzip' length 2679598 bytes (2.6 Mb)
URL을 열었습니다
=====
downloaded 2.6 Mb
```

The downloaded binary packages are in
/var/folders/28/g8cf_pvx46s5phqgwr6qq7jw0000gn/T//RtmpKrDACp/downloaded_packages

- 상관 계수 행렬을 시각화 하기에 앞서 사용할 패키지를 설치하여 준다.
- `Install.packages("corrplot")`

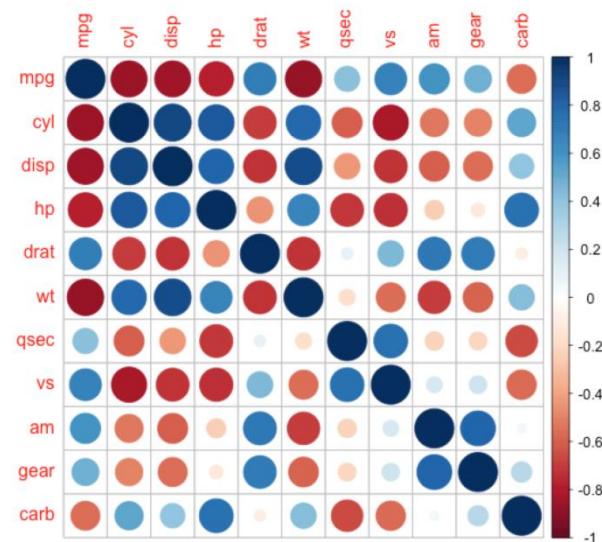
Correlation Analysis with R

● 상관계수 행렬 값을 활용한 히트 맵(Hitmap)

```
> library(corrplot)
> mcor<-cor(mtcars_2)
> round(mcor,2)

  mpg cyl disp hp drat wt qsec vs am gear carb
mpg  1.00 -0.85 -0.85 -0.78  0.68 -0.87  0.42  0.66  0.60  0.48 -0.55
cyl -0.85  1.00  0.90  0.83 -0.70  0.78 -0.59 -0.81 -0.52 -0.49  0.53
disp -0.85  0.90  1.00  0.79 -0.71  0.89 -0.43 -0.71 -0.59 -0.56  0.39
hp   -0.78  0.83  0.79  1.00 -0.45  0.66 -0.71 -0.72 -0.24 -0.13  0.75
drat  0.68 -0.70 -0.71 -0.45  1.00 -0.71  0.09  0.44  0.71  0.70 -0.09
wt   -0.87  0.78  0.89  0.66 -0.71  1.00 -0.17 -0.55 -0.69 -0.58  0.43
qsec  0.42 -0.59 -0.43 -0.71  0.09 -0.17  1.00  0.74 -0.23 -0.21 -0.66
vs    0.66 -0.81 -0.71 -0.72  0.44 -0.55  0.74  1.00  0.17  0.21 -0.57
am    0.60 -0.52 -0.59 -0.24  0.71 -0.69 -0.23  0.17  1.00  0.79  0.06
gear  0.48 -0.49 -0.56 -0.13  0.70 -0.58 -0.21  0.21  0.79  1.00  0.27
carb -0.55  0.53  0.39  0.75 -0.09  0.43 -0.66 -0.57  0.06  0.27  1.00

> corrplot(mcor)
```

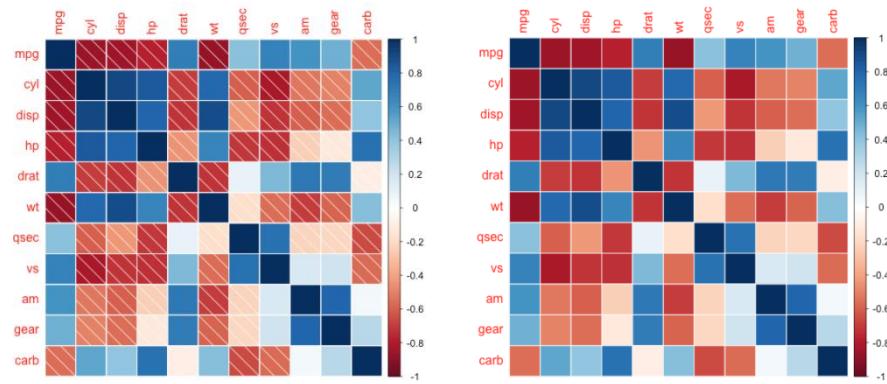
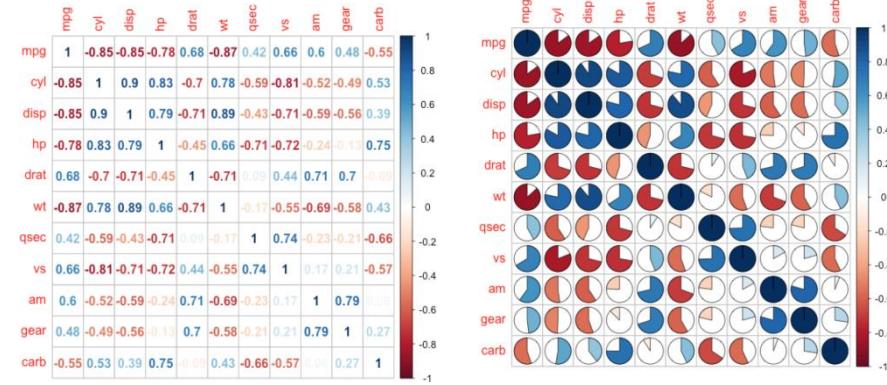
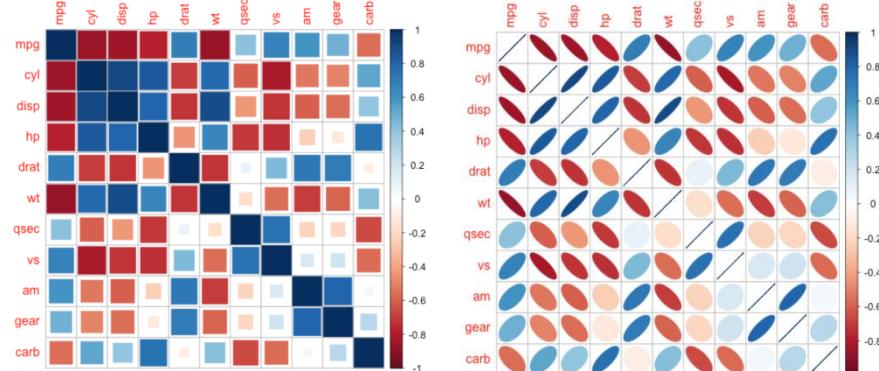


- 디폴트 값으로 설정되어 있는 히트맵은 위의 상관 행렬 표를 원으로 표시하고 계수의 크기를 원의 크기로 표현하여 각 변수의 관계를 손쉽게 확인 할 수 있다.

Correlation Analysis with R

- Method에 따른 히트맵 시각화

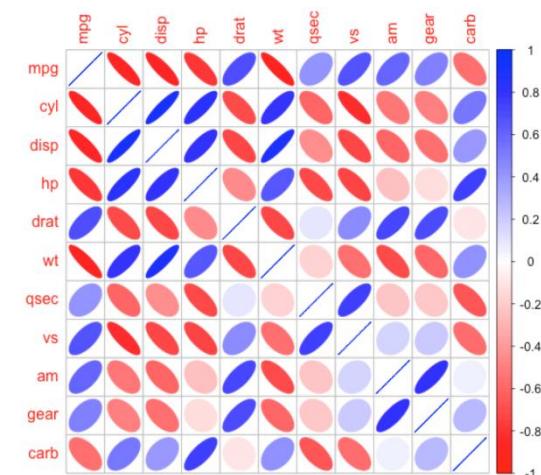
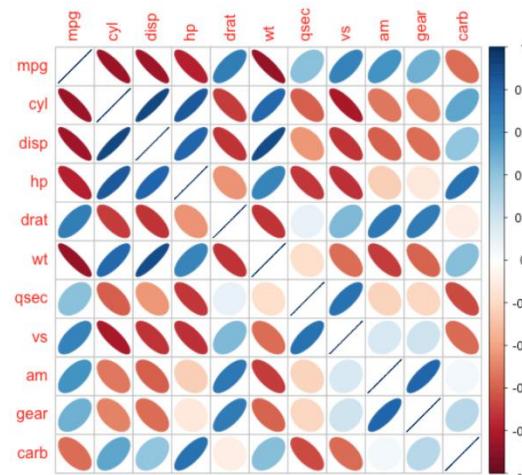
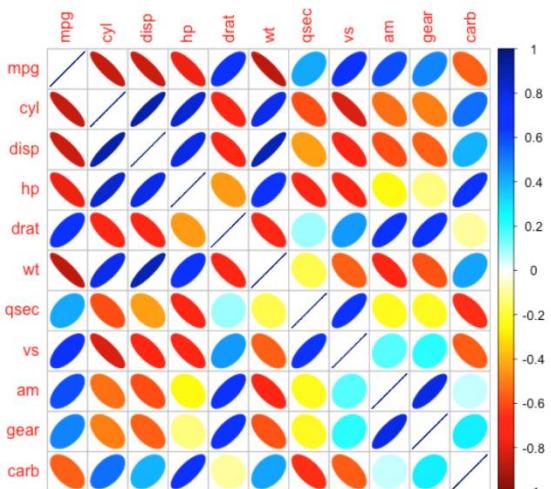
```
> corrplot(mcor, method="square")
>
> corrplot(mcor, method="ellipse")
>
> corrplot(mcor, method="number")
>
> corrplot(mcor, method="pie")
>
> corrplot(mcor, method="shade")
>
> corrplot(mcor, method="color")
```



Correlation Analysis with R

- 색상에 따른 히트맵 시각화

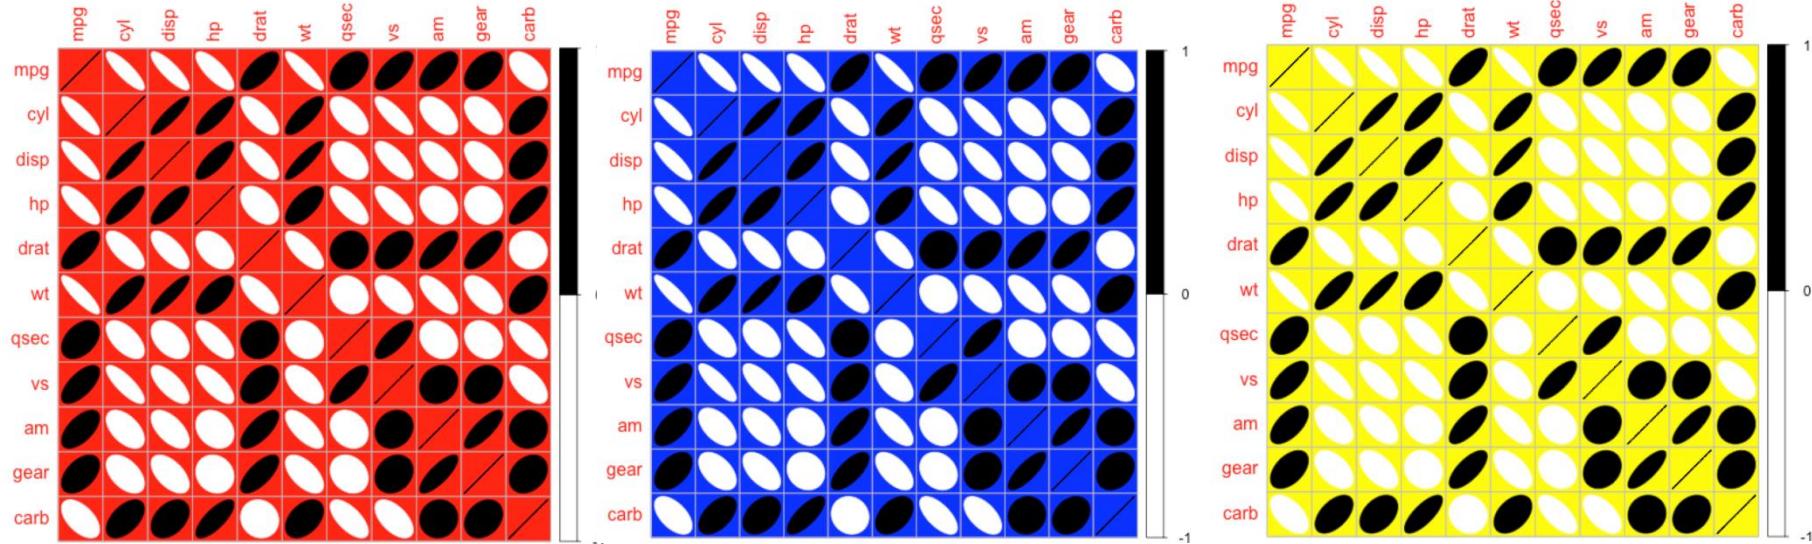
```
> col1 <- colorRampPalette(c("#7F0000", "red", "#FF7F00", "yellow", "white",
+                               "cyan", "#007FFF", "blue", "#00007F"))
>
> col2 <- colorRampPalette(c("#67001F", "#B2182B", "#D6604D", "#F4A582", "#FDDBC7",
+                               "#FFFFFF", "#D1E5F0", "#92C5DE", "#4393C3", "#2166AC", "#053061"))
>
> col3 <- colorRampPalette(c("red", "white", "blue"))
>
> wb <- c("white", "black")
> corrplot(mcor, method="ellipse", col = col1(200))
> corrplot(mcor, method="ellipse", col = col2(200))
> corrplot(mcor, method="ellipse", col = col3(200))
> corrplot(mcor, method="ellipse", col = wb)
```



Correlation Analysis with R

- 배경에 따른 히트맵 시각화

```
> corrplot(mcor, method="ellipse", col = wb, bg = "red")
> corrplot(mcor, method="ellipse", col = wb, bg = "blue")
> corrplot(mcor, method="ellipse", col = wb, bg = "yellow")
```

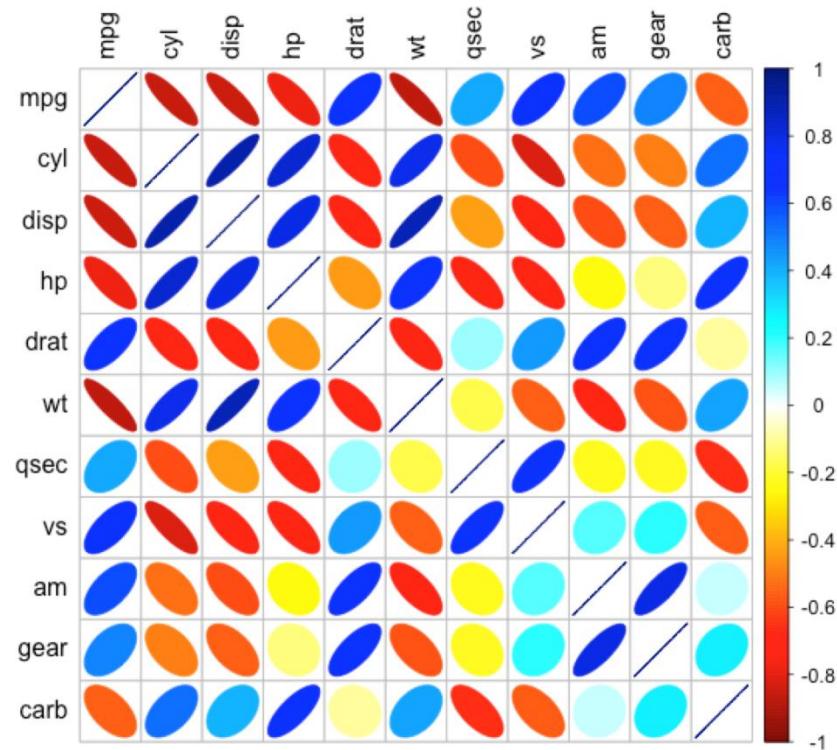
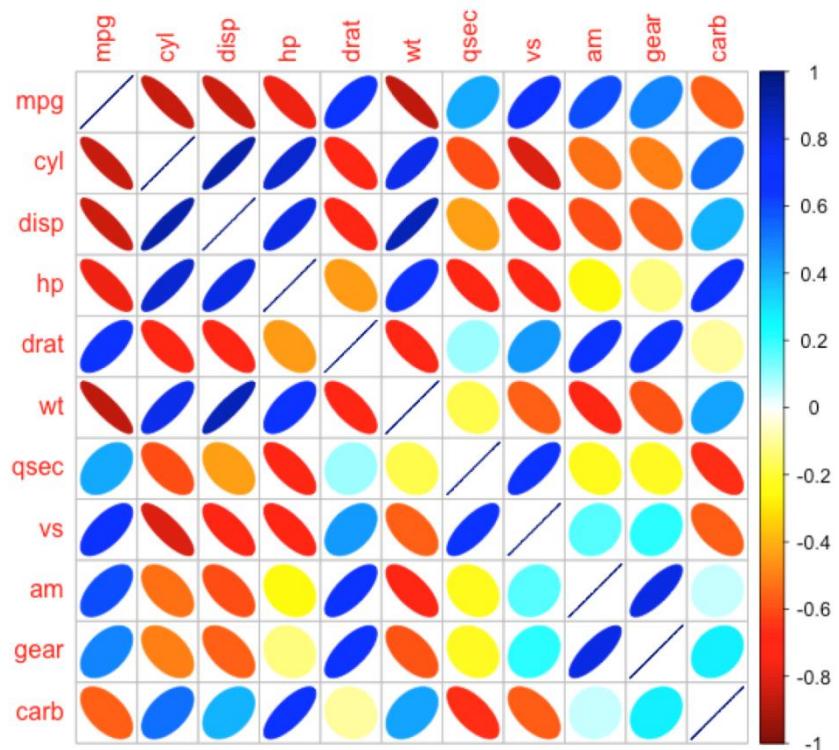


Correlation Analysis with R

- 변수명 색상에 따른 히트맵 시각화

```
> corrplot(mcor, method="ellipse", col = col1(200))
```

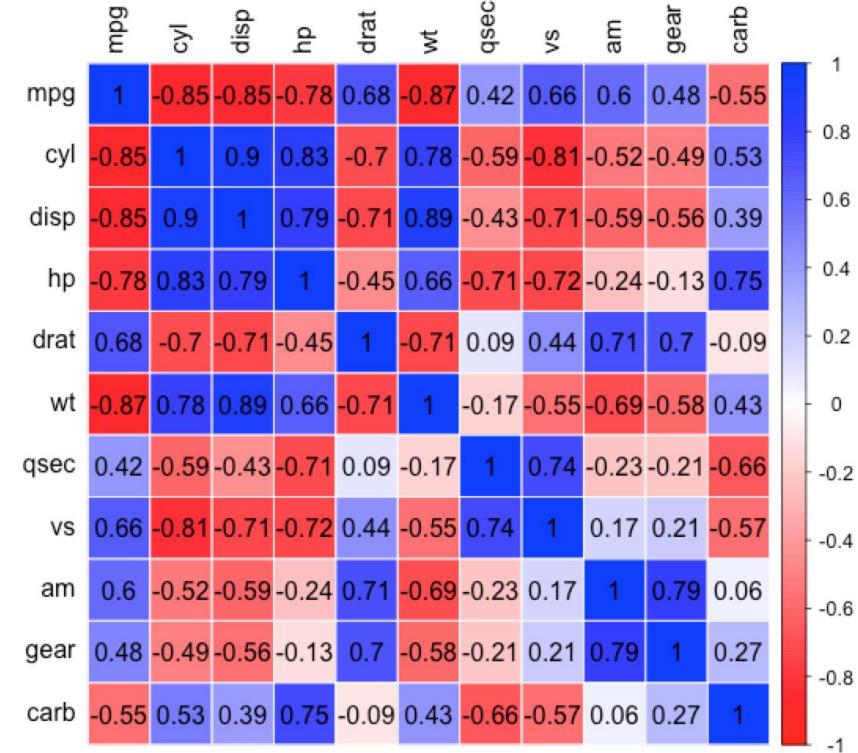
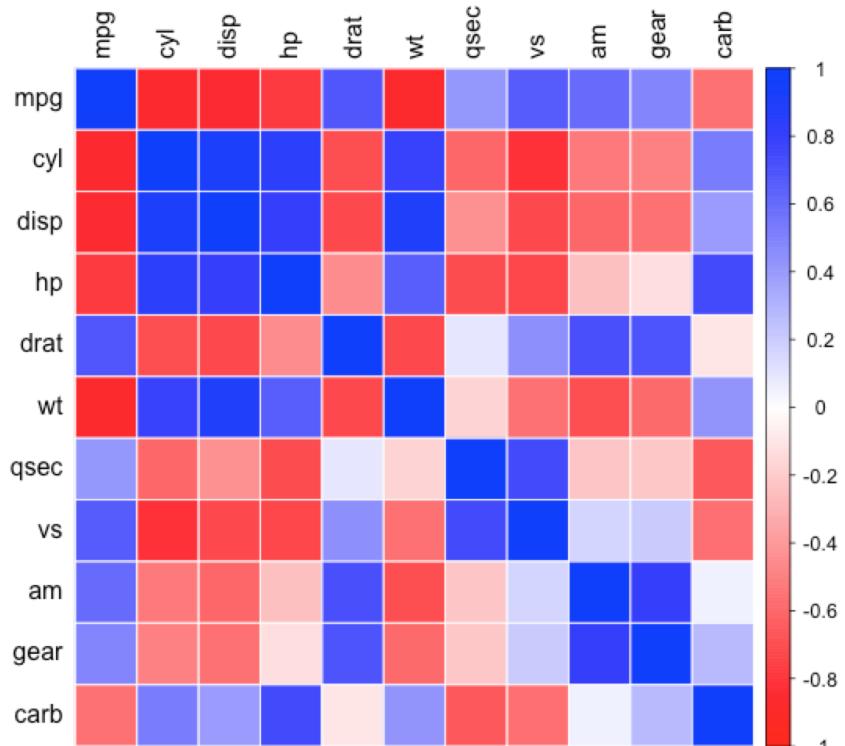
```
> corrplot(mcor, method="ellipse", col = col1(200), tl.col="black")
```



Correlation Analysis with R

- 상관계수 값 표현에 따른 히트맵 시각화

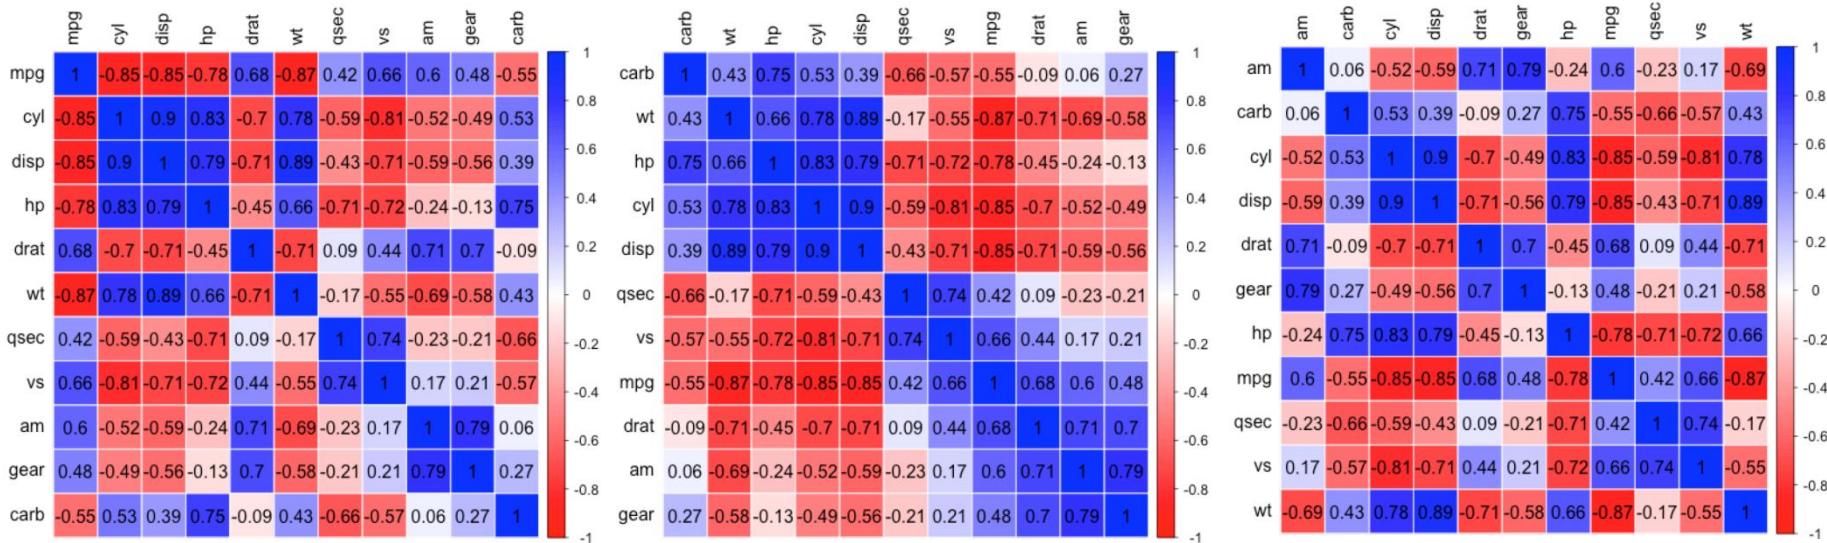
```
> corrplot(mcor, method="color", col = col3(200), tl.col="black")
> corrplot(mcor, method="color", col = col3(200), tl.col="black", addCoef.col="black")
```



Correlation Analysis with R

- 변수간 순서 표현에 따른 히트맵 시각화

```
> corrplot(mcor, method="color", col = col3(200), tl.col="black", addCoef.col="black")
> corrplot(mcor, method="color", col = col3(200), tl.col="black", addCoef.col="black", order="hc
lust")
> corrplot(mcor, method="color", col = col3(200), tl.col="black", addCoef.col="black", order="al
phabet")
>
```



Correlation Analysis with R

- 제목 표현에 따른 히트맵 시각화

```
> corrplot(mcor, method="color", col = col3(200), tl.col="black", addCoef.col="black", order="alphabet", title="corrplot_alphaabet")
```

