




電影票房預測

陳昱鈞
張頌平
曹書誠



取得電影排名

Rank	Movie Title (click to view)	Studio	Total Gross / Theaters		Opening / Theaters		Open	Close
		Artsploitati						
1	Star Wars: The Last Jedi	BV	\$620,181,382	4,232	\$220,009,584	4,232	12/15	4/19
2	Beauty and the Beast (2017)	BV	\$504,014,165	4,210	\$174,750,616	4,210	3/17	7/13
3	Wonder Woman	WB	\$412,563,408	4,165	\$103,251,471	4,165	6/2	11/9
4	Jumanji: Welcome to the Jungle	Sony	\$404,515,480	3,849	\$36,169,328	3,765	12/20	-
5	Guardians of the Galaxy Vol. 2	BV	\$389,813,101	4,347	\$146,510,104	4,347	5/5	9/21

- ❖ 從BoxOfficeMojo網站抓取美國2013至2017共5年票房前100名的電影



取得各個電影資訊



Star Wars: The Last Jedi

Domestic Total Gross: **\$620,181,382**

Distributor: **Buena
Vista**

Release Date:
December 15, 2017


Genre: **Sci-Fi Fantasy**

Runtime: **2 hrs. 31 min.**

MPAA Rating: **PG-13**

Production Budget: **N/A**


- ❖ Genre：電影類型
- ❖ Runtime：電影片長
- ❖ MPAA Rating：電影分級



新變量

- ❖ \$Playing_day：確切總上映天數（下檔日期-上映日期）
- ❖ \$Running.time：片長（以分鐘計）
- ❖ \$Running.length：依片長分等級

< 90	90 ~ 120	120 ~ 150	> 150
short	medium	medium long	long



新變量


- ❖ \$Gross_level：票房收入（以億計，取小數點前一位）
- ❖ \$Ranking：將每年排名前100名再分級

Yearly_Ranking	1 - 10	11 - 20	21 - 30	31 - 40	40 -
Ranking	1	2	3	4	5



電影分級


Rating Distribution





Rating





- General Audiences (一般觀眾)
- Parental Guidance Suggested (建議家長陪同)
- Parents Strongly Cautioned (家長須特別注意)
- Restricted (限制級)




各電影分級的總票房 / 片長





電影類型數量







電影類型的總票房





各電影類型分級的總票房





新變量




Genre: 原本的電影類型

Type: 簡化後的電影類型

Genre


Action	Crime Thriller	Romance
Action / Adventure	Drama	Romantic Comedy
Action / Crime	Drama / Thriller	Romantic Thriller
Action Comedy	Family	Sci-Fi
Action Drama	Family Adventure	Sci-Fi Action
Action Fantasy	Family Comedy	Sci-Fi Adventure
Action Horror	Fantasy	Sci-Fi Fantasy
Action Thriller	Fantasy Drama	Sci-Fi Horror
Adventure	Foreign	Sci-Fi Thriller
Animation	Historical Epic	Sports Comedy
Comedy	Horror	Sports Drama
Comedy / Drama	Horror Comedy	Thriller
Comedy Thriller	Horror Thriller	War
Concert	Music Drama	War Drama
Crime	Musical	Western
Crime Comedy	Period Action	Western Comedy
Crime Drama	Period Adventure	



Type


Action
Adventure
Animation
Comedy
Crime
Drama
Family
Fantasy
Foreign
Horror
Music
Romance
Sci-Fi
Thriller
War


電影類型數量






各電影類型的平均票房






各電影類型的平均上映天數






各製片公司的電影數量







各製片公司的平均票房







各製片公司分級的總票房






各製片公司的電影排名數量






電影片長分佈

Running time Distribution




Running_Length Distribution






各電影片長排名分佈






各電影片長總票房分佈






各月份上映電影數





不同節日電影上映比例



Holiday	Month_Percentage
<chr>	<dbl>
1 Christmas	0.226
2 Halloween	0.0780
3 None	0.420
4 Summer	0.276




不同節日電影上映比例


Holiday	Month_Percentage
<chr>	<dbl>
1 Christmas	0.226
2 Halloween	0.0780
3 None	0.420
4 Summer	0.276

Type	Number	Summer_Percentage	Christmas_Percentage	Halloween_Percentage
<fct>	<dbl>	<dbl>	<dbl>	<dbl>
1 Action	121.	0.347★	0.124	0.0413
2 Adventure	61.	0.311★	0.197	0.
3 Animation	53.	0.358★	0.226	0.0377
4 Comedy	120.	0.292	0.242	0.0500
5 Crime	9.	0.111	0.333	0.222
6 Drama	104.	0.212	0.385★	0.0865
7 Family	11.	0.273	0.273	0.0909
8 Fantasy	18.	0.278	0.333	0.111
9 Foreign	1.	1.00	0.	0.
10 Horror	46.	0.283	0.0217	0.217★
11 Music	6.	0.333	0.667	0.
12 Romance	6.	0.167	0.	0.167
13 Sci-Fi	41.	0.268	0.171	0.0732
14 Thriller	43.	0.256	0.0465	0.140★
15 War	3.	0.333	0.333	0.333





各月份上映電影分級分佈






上映週票房和總票房的關係





上映週和總上映影城數的關係



多變數線性迴歸模型

- ❖ 用2013到2016的資料，當作線性迴歸模型的Train，2017的資料當作被預測的Test

```
dataTrain = subset(data, Year != 2017)
dataTest2017 = subset(data, Year == 2017)
```

- ❖ 分析目標：用一部電影的各種資料，來預測其總票房

多變數線性迴歸模型

- ❖ 分析流程：
 - ❖ 一、選定哪些是適合的變數
 - ❖ 二、預測結果
 - ❖ 三、觀察預測的準確性

多變數線性迴歸模型


- ❖ 應變量：總票房
- ❖ 可使用的自變量：開幕票房、總上映戲院數、開幕上映戲院數、上映年份、上映月份、總上映天數、電影長度、電影分級、電影種類、片商

多變數線性迴歸模型：變數選擇

- ❖ 預測時，若使用總上映天數、總上映戲院數這兩個變數，似乎不太合理
 - ❖ 此兩個變數的確切值，無法在電影下片前得知，所以這樣的模型只有在下片後才能跑，利用價值不大
 - ❖ 此兩個變數的數值高，可能是總票房好的結果，而非原因

多變數線性迴歸模型：變數選擇

- ❖ 回顧：上映戲院數有時候會有大幅成長的現象



多變數線性迴歸模型：變數選擇

- ❖ 製造一個虛構（dummy）變數：
 - ❖ 「是否上映戲院數有大幅成長」
 - ❖ 把總上映戲院數 / 開幕上映戲院數 > 25 ，作為一個鑑別上映戲院數快速成長的虛構變數
 - ❖ 虛構變數：若符合此條件則為1，否則為0

多變數線性迴歸模型：變數選擇

- ❖ 先嘗試性地對所有變數做線性迴歸
 - ❖ 應變量：總票房
 - ❖ 自變量：開幕票房、開幕上映戲院數、上映年份、上映月份、電影長度、電影分級、電影種類、片商、是否上映戲院數有大幅成長

多變數線性迴歸模型：變數選擇

- ❖ 接著挑出統計上顯著（ $p\text{-value}=0.05$ 為門檻）的變數，為以下幾項：
 - ❖ 開幕票房
 - ❖ 開幕上映戲院數
 - ❖ 是否上映戲院數有大幅成長
 - ❖ 開幕月份（為12月的時候）
 - ❖ 片商（為BV、Fox、LGS、Sony、STX、Tris、WB的時候）
 - ❖ 電影種類（為Animation、Sci-Fi Fantasy、Sci-Fi Thriller的時候）

多變數線性迴歸模型：變數選擇

- ❖ 為以上幾個統計上顯著的屬質變量，分別製造虛構變數
- ❖ 再用這些統計上顯著的變量，重新做一次線性迴歸

多變數線性迴歸模型：變數選擇

```
lm(formula = Total_Gross ~ Opening_Gross + Number_of_Opening_Theaters +  
    Large_theater_growth + Open_Month_Dec + Studio_BV + Studio_Fox +  
    Studio_LGS + Studio_Sony + Studio_STX + Studio_TriS + Studio_WB +  
    Genre_Animation + Genre_SciFiFantasy + Genre_SciFiThriller,  
    data = data2Train)
```

Residuals:

	Min	1Q	Median	3Q	Max
	-131178772	-14752179	-1836604	11680023	271252241

Coefficients:

	Estimate	Std. Error	t value	Pr(> t)	
(Intercept)	1.496e+07	1.095e+07	1.367	0.172500	
Opening_Gross	2.788e+00	7.022e-02	39.699	< 2e-16	***
Number_of_Opening_Theaters	-6.920e+03	3.896e+03	-1.776	0.076461	.
Large_theater_growth	4.017e+07	1.259e+07	3.190	0.001541	**
Open_Month_Dec	3.856e+07	5.804e+06	6.644	1.05e-10	***
Studio_BV	2.806e+07	6.504e+06	4.315	2.03e-05	***
Studio_Fox	7.885e+06	5.930e+06	1.330	0.184383	
Studio_LGS	9.968e+06	9.023e+06	1.105	0.269958	
Studio_Sony	1.105e+07	6.652e+06	1.660	0.097644	.
Studio_STX	2.551e+07	2.009e+07	1.270	0.204804	
Studio_TriS	1.085e+07	1.132e+07	0.958	0.338504	
Studio_WB	1.317e+07	5.212e+06	2.527	0.011912	*
Genre_Animation	4.562e+07	6.356e+06	7.178	3.66e-12	***
Genre_SciFiFantasy	9.398e+07	2.531e+07	3.714	0.000234	***
Genre_SciFiThriller	2.576e+07	1.743e+07	1.478	0.140173	

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 34430000 on 385 degrees of freedom

Multiple R-squared: 0.8889, Adjusted R-squared: 0.8849

F-statistic: 220.1 on 14 and 385 DF, p-value: < 2.2e-16

多變數線性迴歸模型：變數選擇

- ❖ 反覆嘗試去除一些已經不再統計上顯著的變數（可能影響力已經被其他變數所解釋）
- ❖ 觀察到開幕上映戲院數的負面效果

多變數線性迴歸模型：變數選擇

- ❖ 最後選定的變數：
 - ❖ 應變量：總票房
 - ❖ 自變量：開幕票房、是否上映戲院數有大幅成長、是否上映月份為12月、是否片商為BV、是否電影種類為Animaiton、是否電影種類為Sci-Fi Fantasy

多變數線性迴歸模型：變數選擇

```
Call:
lm(formula = Total_Gross ~ Opening_Gross + Large_theater_growth +
    Open_Month_Dec + Studio_BV + Genre_Animation + Genre_SciFiFantasy,
    data = data2Train)
```

Residuals:

Min	1Q	Median	3Q	Max
-122024956	-15384882	-2279130	10042454	278194740

Coefficients:

	Estimate	Std. Error	t value	Pr(> t)	
(Intercept)	1.474e+06	2.653e+06	0.556	0.578729	
Opening_Gross	2.716e+00	5.795e-02	46.871	< 2e-16	***
Large_theater_growth	5.623e+07	6.582e+06	8.543	2.92e-16	***
Open_Month_Dec	3.925e+07	5.730e+06	6.850	2.86e-11	***
Studio_BV	2.208e+07	6.173e+06	3.577	0.000391	***
Genre_Animation	4.210e+07	5.982e+06	7.038	8.76e-12	***
Genre_SciFiFantasy	9.459e+07	2.534e+07	3.732	0.000218	***

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 34640000 on 393 degrees of freedom
Multiple R-squared: 0.8852, Adjusted R-squared: 0.8835
F-statistic: 505.3 on 6 and 393 DF, p-value: < 2.2e-16

多變數線性迴歸模型：預測結果

- ❖ 拿線性迴歸模型所估計的參數，跑2017年的電影資料

```
linearMod2.overall.refined2 <- lm(data=data2Train, Total_Gross ~ Opening_Gross + Large_theater_growth +  
  Open_Month_Dec + Studio_BV + Genre_Animation + Genre_SciFiFantasy)
```

```
data2Test2017$Predicted_Total_Gross<-predict(linearMod2.overall.refined2, data2Test2017)
```

多變數線性迴歸模型：預測結果

```
> print(data2Test2017[c("Title", "Predicted_Yearly_Ranking", "Predicted_Total_Gross")])
```

	Title	Predicted_Yearly_Ranking	Predicted_Total_Gross
401	Star Wars: The Last Jedi	1	754991233
402	Beauty and the Beast (2017)	2	498214119
405	Guardians of the Galaxy Vol. 2	3	421506972
408	Thor: Ragnarok	4	356955941
407	It	5	336663956
406	Spider-Man: Homecoming	6	319345632
403	Wonder Woman	7	281927044
412	The Fate of the Furious	8	269799804
410	Justice League	9	256369598
411	Logan	10	241619703
409	Despicable Me 3	11	240318178
421	Cars 3	12	211482312
413	Coco	13	203643128
419	Pirates of the Caribbean: Dead Men Tell No Tales	14	194630546
416	The LEGO Batman Movie	15	187540714
417	The Boss Baby	16	179922925
420	Kong: Skull Island	17	167232384
422	War for the Planet of the Apes	18	154296320
404	Jumanji: Welcome to the Jungle	19	138968258
414	Dunkirk	20	138679633
427	Fifty Shades Darker	21	128069473
425	Transformers: The Last Knight	22	122834856
438	Ferdinand	23	119224074
437	Power Rangers (2017)	24	110938443
436	The Emoji Movie	25	110206033
423	Split	26	110152608
443	Captain Underpants: The First Epic Movie	27	108357968
433	Kingsman: The Golden Circle	28	107469088
500	The Disaster Artist	29	100244614
442	Alien: Covenant	30	99694240
447	The LEGO Ninjago Movie	31	99072693

多變數線性迴歸模型：準確性觀察

- ❖ 比對預測的總票房和實際上的總票房，兩者的相關係數為0.93
- ❖ 預測目標一：預測票房達到 150 million 門檻的電影清單
- ❖ 預測目標二：預測年度前 20 名的電影清單

一、預測票房達到 150 million 門檻的電影清單

- ❖ 準確度：預測會達到 150 million 的18部電影中，總共有17部的實際票房，真的達到了 150 million 的門檻
- ❖ （沒達到門檻的有1部，其實際票房為 146 million ）

	Title	Predicted_Total_Gross	Total_Gross
401	Star Wars: The Last Jedi	754991233	620181382
402	Beauty and the Beast (2017)	498214119	504014165
405	Guardians of the Galaxy Vol. 2	421506972	389813101
408	Thor: Ragnarok	356955941	315058289
407	It	336663956	327481748
406	Spider-Man: Homecoming	319345632	334201140
403	Wonder Woman	281927044	412563408
412	The Fate of the Furious	269799804	226008385
410	Justice League	256369598	229024295
411	Logan	241619703	226277068
409	Despicable Me 3	240318178	264624300
421	Cars 3	211482312	152901115
413	Coco	203643128	209726015
419	Pirates of the Caribbean: Dead Men Tell No Tales	194630546	172558876
416	The LEGO Batman Movie	187540714	175750384
417	The Boss Baby	179922925	175003033
420	Kong: Skull Island	167232384	168052812
422	War for the Planet of the Apes	154296320	146880162


二、預測年度前20名的電影清單

- ❖ 準確度：預測的年度前20名電影中，有18部真的進入了該年實際排名的前20名
- ❖ （沒進入前20名的有2部，實際排名分別為第21名、第22名）

	Title	Predicted_Yearly_Ranking	Yearly_Ranking
401	Star Wars: The Last Jedi	1	1
402	Beauty and the Beast (2017)	2	2
405	Guardians of the Galaxy Vol. 2	3	5
408	Thor: Ragnarok	4	8
407	It	5	7
406	Spider-Man: Homecoming	6	6
403	Wonder Woman	7	3
412	The Fate of the Furious	8	12
410	Justice League	9	10
411	Logan	10	11
409	Despicable Me 3	11	9
421	Cars 3	12	21
413	Coco	13	13
419	Pirates of the Caribbean: Dead Men Tell No Tales	14	19
416	The LEGO Batman Movie	15	16
417	The Boss Baby	16	17
420	Kong: Skull Island	17	20
422	War for the Planet of the Apes	18	22
404	Jumanji: Welcome to the Jungle	19	4
414	Dunkirk	20	14




IMDb參數加入





各電影的IMDb分數與其票房



使用 xgboost 預測

- ❖ 用2013到2016的資料，當作xgboost模型的Train，2017的資料當作被預測的Test

```
# xgboost  
data2 = subset(data, Year != 2017)  
data3 = subset(data, Year == 2017)
```

xgboost 預測用變數

- ❖ 選擇做為預測的變數：製片公司、開幕票房、首映戲院數、片長、類型、分級、上映月份、IMDb分數
- ❖ 因為xgboost的變數皆要是數值型，所以我們在預測前作轉換

xgboost 預測目標

- ❖ 預測目標一：預測票房達到 150M 門檻的電影清單
- ❖ 預測目標二：預測年度前 20 名的電影清單

預測票房達到150M的結果

- ❖ 準確度：預測會達到 150M 的21部電影中，全部的實際票房，都達到了 150M 的門檻

```
> subset(data6, Previous_Gross >= 150000000)
```

	Title	Previous_Gross	Total_Gross
1	Star Wars: The Last Jedi	620181382	634124288
2	Beauty and the Beast (2017)	504014165	482559264
3	Wonder Woman	412563408	383158592
4	Jumanji: Welcome to the Jungle	404515480	387792896
5	Guardians of the Galaxy Vol. 2	389813101	406779264
6	Spider-Man: Homecoming	334201140	339689376
7	It	327481748	336542752
8	Thor: Ragnarok	315058289	337063232
9	Despicable Me 3	264624300	263660912
10	Justice League	229024295	229074672
11	Logan	226277068	230771936
12	The Fate of the Furious	226008385	228742896
13	Coco	209726015	199353920
14	Dunkirk	188045546	194746128
15	Get Out	176040665	175969056
16	The LEGO Batman Movie	175750384	176151856
17	The Boss Baby	175003033	175917552
18	The Greatest Showman	174016519	175017312
19	Pirates of the Caribbean: Dead Men Tell No Tales	172558876	167233120
20	Kong: Skull Island	168052812	169689456
21	Cars 3	152901115	152124880


預測年度前20名的結果

- ❖ 準確度：預測的年度前20名電影中，全部進入了該年實際排名的前20名
- ❖ 甚至有10部是直接命中！其他幾乎只有一部的差距


```
> subset(data6, Ranking <= 20)
```

	Ranking	Title
1	1	Star Wars: The Last Jedi
2	2	Beauty and the Beast (2017)
3	5	Wonder Woman
4	4	Jumanji: Welcome to the Jungle
5	3	Guardians of the Galaxy Vol. 2
6	6	Spider-Man: Homecoming
7	8	It
8	7	Thor: Ragnarok
9	9	Despicable Me 3
10	11	Justice League
11	10	Logan
12	12	The Fate of the Furious
13	13	Coco
14	14	Dunkirk
15	16	Get Out
16	15	The LEGO Batman Movie
17	17	The Boss Baby
18	18	The Greatest Showman
19	20	Pirates of the Caribbean: Dead Men Tell No Tales
20	19	Kong: Skull Island

預測年度前100名的結果



預測年度前100名的結果



xgboost 預測目標

- ❖ 雖然排名準確，但我們真正想知道的是預測票房的能力
- ❖ 我們拿預測的票房和實際票房相減，除以實際票房，得到誤差

```
> error <- mean(abs(data3$Total_Gross - data$Total_Gross[401:500]) / data$Total_Gross[401:500])  
> 100*(1 - error)  
[1] 98.58225
```

- ❖ 準確率高達 98.58 % ！

檢討與改進

- ❖ 有更多變量可以使用，可能使得結果更好(ex:有名演員、導演的影響、imdb關注數量、評論的內容等等...)
- ❖ 爬蟲過程中，有少許資料遺失(人工補齊)

檢討與改進

- ❖ 進階目標：如果能在還沒上映就能準確預測首週和總票房
- ❖ 影響：可以讓電影公司決定如何制訂他們的行銷策略
(如果上映前預測首週票房低於原先預期，可能需要更多廣告等等...)