Mazourek

September 2, 2022

1 Domácí výhoda ve fotbale

Bedřich Mazourek

Domácí výhoda je fenomén, kdy týmy hrající ve svém domácím stadionu vyhrávají častěji než hosté. Tento jev se vysvětluje několika faktory:

- 1) Domácí tým má podporu fanoušků, takže hraje lépe
- 2) Rozhodčí podvědomě pískají méně faulů způsobených domácím týmem, aby na ně nebučelo publikum.
- 3) Domácí tým hraje na svém teritoriu, takže má větší psychologickou sebejistotu
- 4) Jev je sebenaplňující proroctví - domácí hráči očekávají, že vyhrají, takže hrají s větší jistotou, což se poté promítne do výsledku

Během covidové pandemie byly stadiony zavřené a hrálo se bez fanoušků, což poskytlo unikátní příležitost tento fenomén pozorovat, a blíže se podívat na vliv prvních dvou faktorů

1.1 Data

Budu používat následují dva soubory dat: - 1) Výsledky mezinárodních zápasů od roku 1872 - https://www.kaggle.com/datasets/martj42/international-football-results-from-1872-to-2017 - 2) Zápasy evropských lig sezóny 2019/20 - https://osf.io/4hu8r/?view_only=1176423f8b594ddbb0d93b5c45856557

1.2 Příklad 1 - Mezinárodní zápasy

- Nejdříve by mě zajímalo, jestli vskutku můžeme pozorovat nějakou domácí výhodu
- K tomu bude potřeba z dat odfiltrovat pryč zápasy hrané na neutrálním uzemí a zápasy během covidu

[2]:
```
import pandas as pd
import matplotlib.pyplot as plt
%matplotlib inline
```

[3]:
```
df = pd.read_csv('international_results.csv')
df = df.iloc[::-1]                                # Reverse

df = df.loc[df['neutral'] == False]               # Games played in non-neutral␣
↪stadiums
```

```
pre_covid = df.loc[df['date'] < '2020-01-01']     # Get all matches played␣
↪before covid (circa 2020)
```

[11]:
```
# Get total number of wins from match results
def get_results(label, home_goals, away_goals):
    if len(home_goals) != len(away_goals):
        print("Different list sizes")
        return

    wins = losses = draws = 0
    for x,y in zip(home_goals, away_goals):
        if x > y:
            wins += 1
        elif x == y:
            draws += 1
        else:
            losses += 1

    pie_chart(label, wins, draws, losses)

    return [wins, draws, losses]

def pie_chart(label,wins,draws,losses):
    y = [wins,draws,losses]
    mylabels = ['Home', 'Draw', 'Away']

    plt.title(label)
    plt.pie(y, labels = mylabels ,shadow=True, autopct='%1.1f%%',)
    plt.show()
```

[66]:
```
home_goals = pre_covid.iloc[:,3].values
away_goals = pre_covid.iloc[:,4].values
inter_matches = len(pre_covid)
print(f'Sample size is: {inter_matches} matches played before covid')
results_pre = get_results('Results of matches before covid', home_goals,␣
↪away_goals);
```

```
Sample size is: 31469 matches played before covid
```

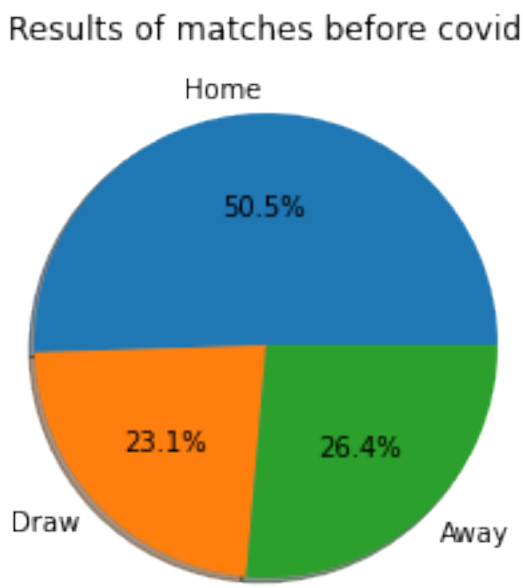

- Hned můžeme vidět, že rozdělení výher a velikost vzorku velmi silně podporuje hypotézu domácí výhody.
- Nyní by mě zajímalo, jestli jde na stejném datasetu pozorovat nějaká změna výsledků pro období coronaviru, kdy byly stadiony povětšinou zavřené a hrálo se bez fanoušků
  - Z internetových článků napsaných v té době jsem udělal hrubý odhad, že stadiony byly nejvíce zavřené od března 2020 do března 2021.
  - Samozřejmě průběh pandemie byl v různých částech světa jiný a určitě v tomto období byly i hry s fanoušky, ale můžeme se pokusit o aproximaci

[10]:
```
covid = df.loc[df['date'] > '2020-03-01'].loc[df['date'] < '2021-03-01']
↪# Matches approximately from the most intense covid period
covid_home = covid.iloc[:,3].values     # Home goals during covid
covid_away = covid.iloc[:,4].values     # Away goals during covid
print(f'Sample size: {len(covid)} matches played during covid')
results_cov = get_results('Results of matches played during covid', covid_home,␣
↪covid_away)
```

```
Sample size: 269 matches played during covid
```

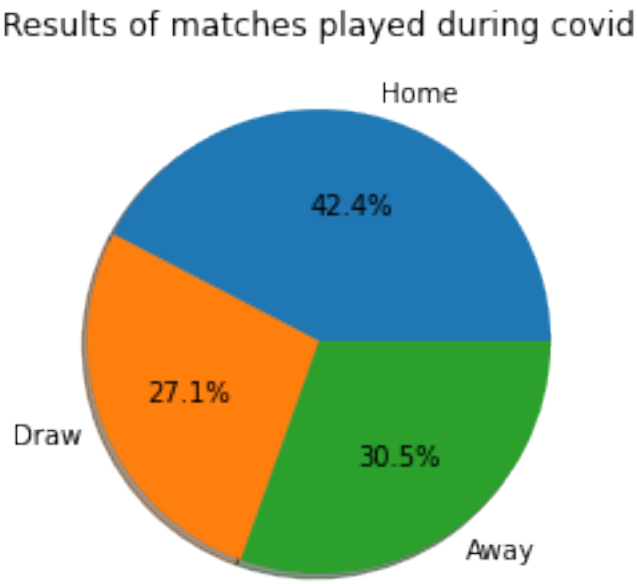

- Přestože je velikost vzorku menší a výběr časového období nejistý, můžeme vidět, že se trend docela výrazně změnil, a domácí vyhráli bez fanoušků pouze 42% her - o 8% méně než předtím
- Pro ověření můžeme použít Pearsonův ^2 test nezávislosti
- Nulová hypotéza bude, že výsledky zápasů jsou nezávislé na tom, jestli se hrají během období covidu (a tedy v prázdných stadionech), nebo ne
- Zvolme hladinu nezávisloti 5%
- Máme 2 stupně nezávislosti, a tedy kritická hodnota bude 5.99

[68]:
```
def test_of_independence(description_x, results_x, description_y, results_y,␣
↪critical_value):
    # Visualize the data in tables
    def plot_tables():
        home_x, draw_x, away_x = results_x
        home_y, draw_y, away_y = results_y
        # Get the total number of matches played during both periods
        total_x = home_x + draw_x + away_x
        total_y = home_y + draw_y + away_y

        total_home = home_x + home_y        # Total home wins in both periods
        total_draw = draw_x + draw_y        # Total draws
        total_away = away_x +  away_y       # Total away wins
        total_abs = total_x + total_y       # Absolute total of matches played

        #* First table
        fig, ax = plt.subplots()
        fig.patch.set_visible(False) # Hide axes
```

```
        ax.axis('off')
        ax.axis('tight')

        cols = ['', 'Home', 'Draw', 'Away', 'Total']
        rows = [[description_x, home_x, draw_x, away_x, total_x],
                [description_y, home_y, draw_y, away_y, total_y],
                ['Total', total_home, total_draw, total_away, total_abs]]


        ax.table(cellText=rows, colLabels=cols, loc='center', cellLoc='center')
        fig.tight_layout()
        plt.title('Observed Results')
        plt.show()


        #* Second table
        fig2, ax2 = plt.subplots()
        fig2.patch.set_visible(False)
        ax2.axis('off')
        ax2.axis('tight')

        # Get the expected results from data
        r1 = [round((x/total_abs) * total_x, 1 ) for x in [total_home,␣
↪total_draw, total_away]] + [total_x]
        r2 = [round((y/total_abs) * total_y, 1 ) for y in [total_home,␣
↪total_draw, total_away]] + [total_y]

        rows2 = [[description_x] + r1,
                [description_y] + r2,
                ['Total', total_home, total_draw, total_away, total_abs]]

        ax2.table(cellText=rows2, colLabels=cols, loc='center',␣
↪cellLoc='center')

        plt.title('Expected Results')
        fig2.tight_layout()
        plt.show()

        return rows, rows2


    rows, rows2 = plot_tables()
    # Get the 6 relavant datapoints from each table
    observed_results = rows[0][1:-1] + rows[1][1:-1]
    expected_results = rows2[0][1:-1] + rows2[1][1:-1]

    chi_sq = 0
```

```
    for obs, exp in zip(observed_results, expected_results):
        chi_sq += (obs - exp)**2 / exp          # Chi-squared formula

    if (chi_sq <= critical_value):
        comparison = 'smaller'
        confidence = 'do not'
    else:
        comparison = 'larger'
        confidence = 'can'

    print(f'Chi-squared is {round(chi_sq,2)}, which is {comparison} than the␣
↪critical value of {critical_value}. Therefore, we {confidence} have enough␣
↪confidence to reject the null hypothesis ')



test_of_independence('Before Covid', results_pre, 'During Covid', results_cov,␣
↪5.99)
```

Observed Results

	Home	Draw	Away	Total
Before Covid	15892	7277	8300	31469
During Covid	114	73	82	269
Total	16006	7350	8382	31738

Expected Results

	Home	Draw	Away	Total
Before Covid	15870.3	7287.7	8311.0	31469
During Covid	135.7	62.3	71.0	269
Total	16006	7350	8382	31738

```
Chi-squared is 7.07, which is larger than the critical value of 5.99. Therefore,
we can have enough confidence to reject the null hypothesis
```

- Pomocí testu nezávislosti můžeme zamítnout nulovou hypotézu nezávislosti
- Pro mezinárodní zápasy tedy můžeme mít solidní jistotu, že výsledky jsou vskutku závislé na přítomnosti fanoušků

1.3 Příklad 2 - Evropské ligy

- Nyní se můžeme podívat na výsledky evropských lig, hrané 2019/2020
- Velká výhoda tohoto datasetu je, že přibližně tři čtvrtiny her se hrály před coronavirem a zbylá čtvrtina během, takže budeme porovnávat jablka s jablky
- Také je v datech přímo řečené, které zápasy se hrály s publikem a které bez, takže teď nemusíme dělat žádné odhady

[15]:
```
df2 = pd.read_excel("europe.xlsx")
full = df2.loc[df2['Covid'] == 0].loc[df2['Venue'] == 1]        # Full stadiums␣
↪before corona
empty = df2.loc[df2['Covid'] == 1].loc[df2['Venue'] == 0]       # Empty stadiums␣
↪during corona
```

[19]:
```
# FTR = Full Time Results
home_wins = full['FTR'].value_counts()['H']      # 'H' = Home Win
draws = full['FTR'].value_counts()['D']          # 'D' = Draw
```

```
away_wins = full['FTR'].value_counts()['A']      # 'A' = Away Win

eu_results_pre = [home_wins, draws, away_wins]  # Save the data for intedepence␣
↪test later

print(f'Sample size is: {len(full)} matches played before coronavirus')
pie_chart('Results with an audience:', home_wins, draws, away_wins)
```

```
Sample size is: 3600 matches played before coronavirus
```

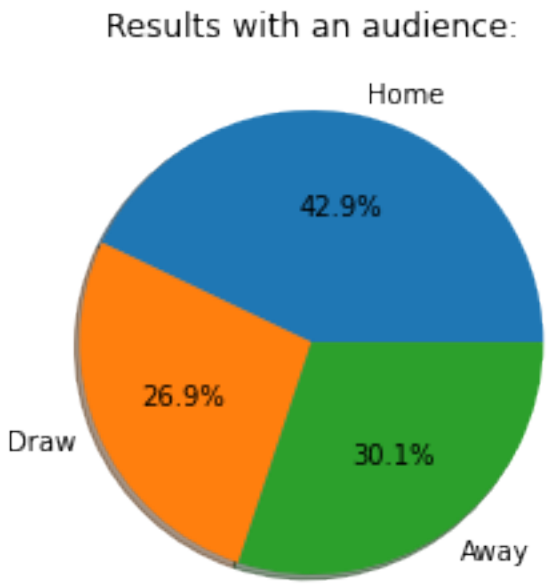

- Okamžitě si můžeme všimnout, že přestože domácí výhodu stále můžeme pozorovat, tak pro evropské ligy je šance výhry domácích o 7% menší než pro mezinárodní zápasy
- Asi je zbytečné spekulovat o tom, proč to tak je, ale jedno vysvětlení by mohlo být, že během mezinárodních zápasů je ve stadionech mnohem více domácích fanoušků než fanouškům hostů.
  - Například pokud hraje Španělsko proti Německu ve španělském stadionu, tak se dá očekávat, že španělských fanoušků bude výrazně více než německých
  - Na druhou stranu při zápase Sparty proti Slávii bude poměr fanoušků relativně rovnoměrný, bez ohledu na to v jakém stadionu se zápas koná
- Každopádně nyní se můžeme podívat na zápasy hrané během coronaviru

[30]:
```
home_wins = empty['FTR'].value_counts()['H']
draws = empty['FTR'].value_counts()['D']
away_wins = empty['FTR'].value_counts()['A']

eu_results_cov = [home_wins, draws, away_wins]
```

```
print(f'Sample size is: {len(empty)} matches played during coronavirus')
pie_chart('Results with no audience:', home_wins, draws, away_wins)
```

```
Sample size is: 1414 matches played during coronavirus
```

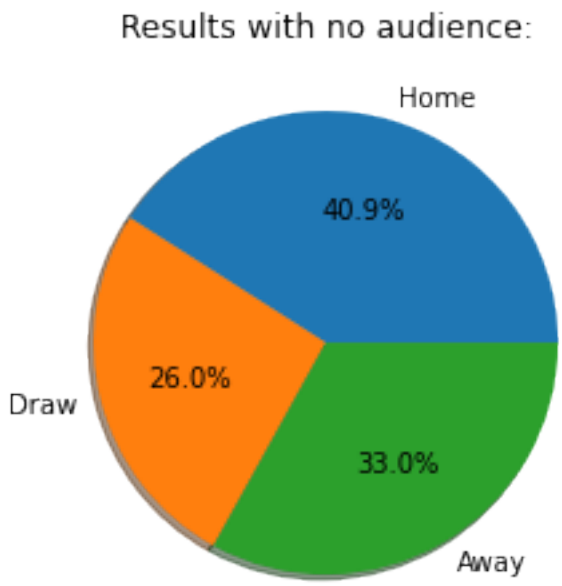

- Přestože pokles není tak drastický jako u mezinárodních zápasů, znovu můžeme pozorovat snížení domácích výher v prázdných stadionech
- To nám, společně s výsledky mezinárodních zápasů, může dát alespoň nějakou jistotu, že fanoušci mají nezanedbatelný vliv na výsledky zápasů
- Pro evropské zápasy můžeme znovu provést test nezávislosti, s hladinou nezávislosti 5%
- Nulová hypotéza znovu bude, že výsledky zápasů jsou nezávislé na tom, jestli se hrají během covidu nebo ne.

[65]:
```
test_of_independence('Before Covid', eu_results_pre, 'During Covid',␣
↪eu_results_cov, 5.99)
```

Observed Results

	Home	Draw	Away	Total
Before Covid	1546	970	1084	3600
During Covid	579	368	467	1414
Total	2125	1338	1551	5014

Expected Results

	Home	Draw	Away	Total
Before Covid	1525.7	960.7	1113.6	3600
During Covid	599.3	377.3	437.4	1414
Total	2125	1338	1551	5014

```
Chi-squared is 4.07, which is smaller than the critical value of 5.99.
Therefore, we do not have enough confidence to reject the null hypothesis
```

- Pro evropské zápasy můžeme přijmout nulovou hypotézu
- To nám říká, že v evropských ligách není plnost stadionů, a tedy i přítomnost fanoušků, dostatečně významná

1.4 Příklad 2.5 - Závislost mezi mezinárodními a evropskými zápasy

- Ještě bychom se mohli podívat, jestli jsou výsledky závislé na tom, jestli se hrají buď jako mezinárodní zápas, nebo jako zápas evropské ligy
- Pro výpočet použijeme stejnou funkci jako předtím, a nejdříve se podíváme na zápasy před covidem s plnými stadiony

[72]:
```
test_of_independence('International', results_pre, 'EU Leagues',␣
↪eu_results_pre, 5.99)
```

Observed Results

	Home	Draw	Away	Total
International	15892	7277	8300	31469
EU Leagues	1546	970	1084	3600
Total	17438	8247	9384	35069

Expected Results

	Home	Draw	Away	Total
International	15647.9	7400.4	8420.7	31469
EU Leagues	1790.1	846.6	963.3	3600
Total	17438	8247	9384	35069

```
Chi-squared is 73.99, which is larger than the critical value of 5.99.
Therefore, we can have enough confidence to reject the null hypothesis
```

- ^2 vyšlo 74, což je výrazně vyšší než kritická hodnota 5.99
- Z toho lze s velmi velkou jistotou zamítnout nulovou hypotézu
- Závěr můžeme učinit takový, že výsledky zápasů s fanoušky silně závisí na tom, jestli se hrají mezinárodně anebo v evropské lize

- Obdobně můžeme udělat znovu stejný test, ale pro období covidu bez fanoušků

[73]:
```
test_of_independence('International', results_cov, 'EU Leagues',␣
↪eu_results_cov, 5.99)
```

Observed Results

	Home	Draw	Away	Total
International	114	73	82	269
EU Leagues	579	368	467	1414
Total	693	441	549	1683

Expected Results

	Home	Draw	Away	Total
International	110.8	70.5	87.7	269
EU Leagues	582.2	370.5	461.3	1414
Total	693	441	549	1683

```
Chi-squared is 0.66, which is smaller than the critical value of 5.99.
Therefore, we do not have enough confidence to reject the null hypothesis
```

- ^2 zde vyšlo velmi malé, obzvlášť v porovnání s předchozím výsledkem 74
- Nulovou hypotézu můžeme přijmout, a říci, že během období covidu bez fanoušků nejsou výsledky závislé na tom, jestli se hraje mezinárodní fotbal anebo evropská liga

1.5 Příklad 3 - Chovaní rozhodčích

- Data o evropských zápasech jsou relativně podrobná a obsahují i počty žlutých a červených karet
- Toho můžeme využít a podívat se, jestli rozhodčí vskutku mění své chování podle toho, jestli je přítomno publikum

[9]:
```
def show_card(card_type):                # card_type = Yellow/Red
    home = 'H' + card_type[0]            # HY = Home Yellow, HR = Home Red
    home_full = get_avg(full, home)      # Home team full stadium
    home_empty = get_avg(empty, home)    # Home team empty stadium

    away = 'A' + card_type[0]            # AY = Away Yellow, AR = Away Red
    away_full = get_avg(full, away)      # Away team full stadium
    away_empty = get_avg(empty, away)    # Away team empty stadium

    plot_graph([home_full, home_empty], [away_full, away_empty], card_type)


# U několika zápasů data o počtu karet chybí, takže průměr spočítáme mírnou␣
↪oklikou
def get_avg(data, type):
    vals = data[type].values
    suma = 0
    counter = 0

    for val in vals:
        try:
            suma += val
            counter += 1
        except TypeError:
            pass

    return suma/counter

def plot_graph(home_stats, away_stats, card_type):
    plt.plot(['Full stadiums', 'Empty stadiums'], home_stats, '-g', label =␣
↪'Home team')
    plt.plot(['Full stadiums', 'Empty stadiums'], away_stats, '-r', label =␣
↪'Away team')
```

```
    plt.title(f'{card_type} cards before and during covid')
    plt.ylabel("Number of cards")

    plt.legend()
    plt.show()

show_card('Yellow')
show_card('Red')
```

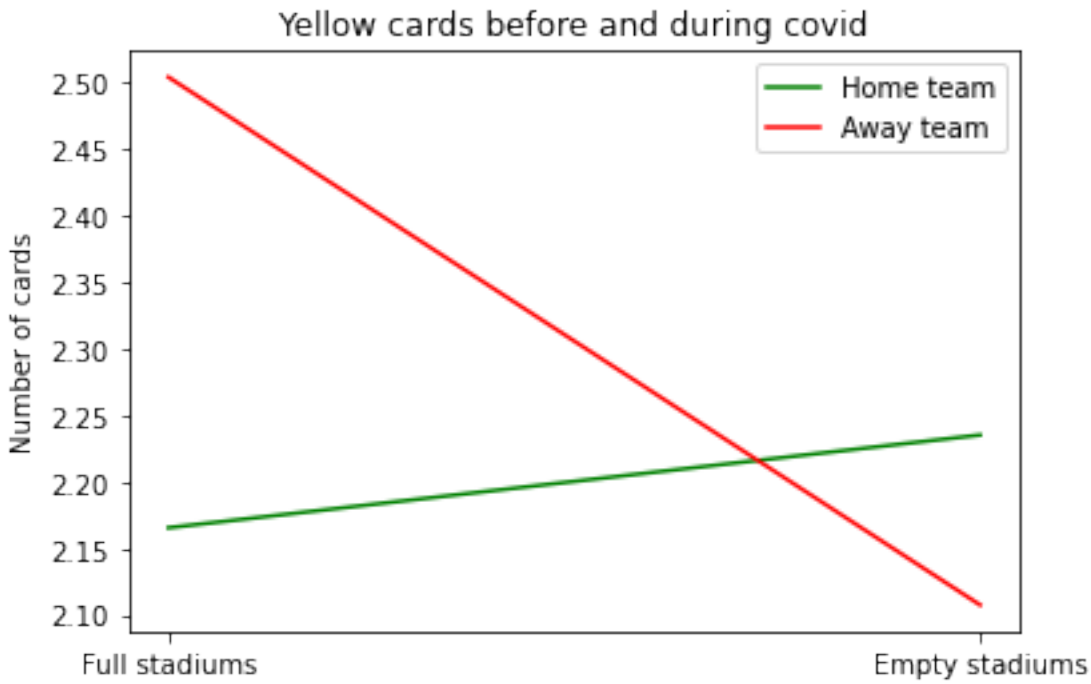

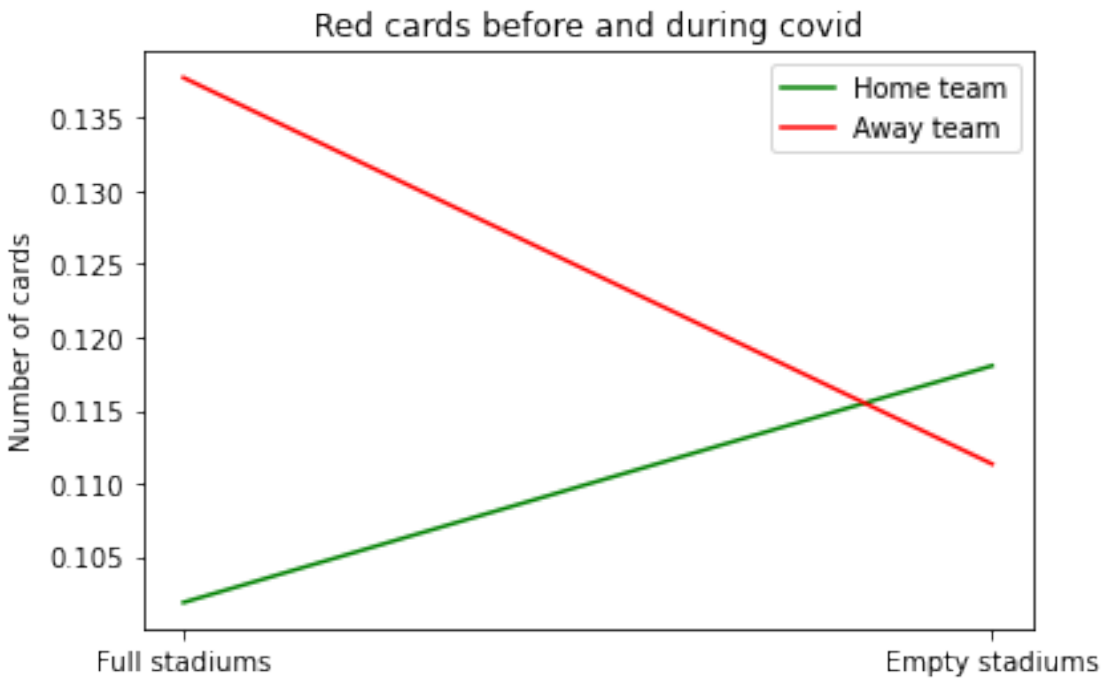

- Z dat můžeme vidět nárůst počtu karet pro domácí a relativně strmé snížení počtu pro hosty
- Domácí týmy také v prázdných stadionech dostávají více karet než hosté. To by se dalo vysvětlit tím, že na domácí půdě jsou hráči agresivnější, a také jsou zvyklí na to, že jim to obvykle rozhodčí častěji promine

1.6 Závěr

- Můžeme s jistotou říci, že domácí výhoda existuje - z dat jsme viděli 50% šanci výhry mezinárodních zápasů a 43% výhry v evropské lize pro domácí týmy
- Také jsme mohli pozorovat snížení domácí výhody ve stadionech bez publika. Z toho můžeme odvodit, že fanoušci mají vliv na výsledek zápasu
- Jeden pozorovatelný vliv fanoušků je na chování rozhodčích, u nichž můžeme vidět, že bez publika dávájí více karet domácím a méně karet hostům, což má potom vliv na výsledek zápasu
- Velmi zajímavé je, že silnou domácí výhodu lze stále pozorovat i bez fanoušků. Pro evropské ligy to byla pravděpodobnost výhry domácích 41%, zatímco hostů pouze 33%
  - Z toho můžeme vydedukovat, že přestože fanoušci mají vliv, existuje více faktorů. Ať je to sebenapňující proroctví, teritoriální sebejistota, či něco úplně jiného, záhada domácí výhody stále přetrvává