

# POLITECNICO DI TORINO



CORSO DI LAUREA MAGISTRALE IN INGEGNERIA  
GESTIONALE

TESI DI LAUREA MAGISTRALE

Applicazione della metodologia Event Study nel settore turistico:  
evidenza empirica sulla piattaforma Airbnb durante il Mondiale di  
Calcio del 2018 disputato in Russia

Candidato:  
GIUSEPPE VITULANO  
Matr. S255514

Relatore:  
Prof. LUIGI BUZZACCHI

Correlatore:  
Dott. FRANCESCO LUIGI MILONE

ANNO ACCADEMICO 2019-2020



# INDICE

INDICE .....	3
ABSTRACT.....	6
CAPITOLO 1 MULTI-SIDED PLATFORM.....	7
1.1 Definizione.....	7
1.2 Big Data .....	8
1.3 Esternalità di rete .....	10
1.4 Pricing Strategy.....	11
1.4.1 Modello di Bertrand - Benchmark .....	11
1.4.2 Modello di Bertrand - Realistico.....	12
1.4.3 Modello di Rochet-Tirole.....	14
1.5 Il dilemma del “Winner Take It All Dynamics” .....	15
1.6 Sharing economy .....	16
1.6.1 Fattori di crescita.....	18
1.6.2 Modelli di platform sharing .....	19
CAPITOLO 2 AIRBNB .....	21
2.1 La storia .....	21
2.2 Cosa è e come funziona? .....	22
2.3 Disruptive innovation theory .....	24
2.4 L’impatto economico e sociale di Airbnb.....	27
2.5 Pricing strategy .....	28
2.6 Crisi economica e aspetti futuri .....	30
2.7 Scopo del lavoro .....	31
2.7.1 Impatto economico del Mondiale di Calcio in Russia .....	31
2.7.2 Domanda di ricerca .....	32
CAPITOLO 3 DATI E METODOLOGIA DI STUDIO .....	35
3.1 Descrizione dei dati - AirDNA dataset.....	35
3.2 Metodologia di studio .....	36
3.2.1 Analisi descrittiva.....	36
3.2.2 Event Study .....	37
CAPITOLO 4 ANALISI DESCRITTIVA.....	41

4.1 Airbnb in Russia .....	42
4.2 Confronto tra le singole città .....	46
CAPITOLO 5 EVENT STUDY .....	54
5.1 Constant Mean Return .....	55
5.1.1 Applicazione e risultati .....	56
5.2 Trend Model .....	58
5.2.1 Applicazione e risultati .....	59
5.3 Trend and Seasonality Model .....	61
5.3.1 Applicazione e risultati .....	63
5.3.2 Alternative Trend and Seasonality Model.....	67
5.3.3 Applicazione e risultati .....	67
CONCLUSIONI E SVILUPPI FUTURI .....	71
BIBLIOGRAFIA .....	73
SITOGRAFIA .....	78
CAPITOLO 6 ALLEGATI.....	79
6.1 Daily Dataset - Caratteristiche.....	79
6.2 Monthly Dataset - Caratteristiche .....	79
6.3 Annual Properties Performance Dataset - Caratteristiche .....	80
6.4 Codici Python .....	81
6.4.1 Codice Estrazione Monthly.....	81
6.4.2 Codice Estrazione e pulizia Daily Dataset.....	81
6.4.3 Analisi Descrittiva.....	83
6.4.4 Regressione lineare .....	85
6.5 Dati descrittivi.....	87
6.5.1 Russia .....	87
6.5.2 Mosca .....	88
6.5.3 San Pietroburgo .....	89
6.5.4 Nizhnij Novgorod.....	90
6.5.5 Kazan.....	91
6.5.6 Samara.....	92
6.5.7 Sochi.....	93
6.6 Constant Mean Return .....	94
6.6.1 San Pietroburgo.....	94

6.6.2 Nizhnij Novgorod.....	95
6.6.3 Kazan.....	96
6.6.4 Samara.....	97
6.6.5 Sochi.....	98
6.7 Trend Model .....	99
6.7.1 San Pietroburgo .....	99
6.7.2 Nizhnij Novgorod.....	100
6.7.3 Kazan.....	101
6.7.4 Samara.....	102
6.7.5 Sochi.....	103
6.8 Trend and Seasonality Model .....	104
6.8.1 San Pietroburgo .....	104
6.8.2 Nizhnij Novgorod.....	106
6.8.3 Kazan.....	108
6.8.4 Samara.....	110
6.8.5 Sochi.....	112
6.9 Alternative Trend and Seasonality Model .....	114
6.9.1 San Pietroburgo .....	114
6.9.2 Nizhnij Novgorod.....	115
6.9.3 Kazan.....	116
6.9.4 Samara.....	117
6.9.5 Sochi.....	118

## ABSTRACT

Il presente lavoro di Tesi ha come scopo l'analisi dell'impatto economico di Mega-Eventi sulla piattaforma di Airbnb attraverso l'applicazione di metodologie di Event Study (ES). Nello specifico, è stato considerato uno degli eventi sportivi più seguiti al mondo: il Mondiale di Calcio del 2018, svoltosi in Russia. Le edizioni della FIFA World Cup sono classificate come Mega-Eventi in quanto, oltre ad incrementare l'attrattività del paese ospitante, attirano e interessano grandi masse di persone che condividono la stessa passione, i mass-media e i molteplici stakeholders appartenenti ai diversi settori economici e sociali. Nel lavoro si è proceduto ad esaminare, mediante una analisi descrittiva, le performance economiche della piattaforma Airbnb in Russia e in particolare nelle città dove si è disputato l'evento sportivo. Infine, il quesito a cui l'elaborato tenterà di rispondere è: "Come uno specifico evento influenza le variabili economiche nel breve periodo?". L'Event Study rappresenta una metodologia di analisi statistica idonea al nostro caso poiché permette di valutare il comportamento delle variabili nel breve arco temporale comprendente l'evento in questione, per poi valutarne la significatività statistica.

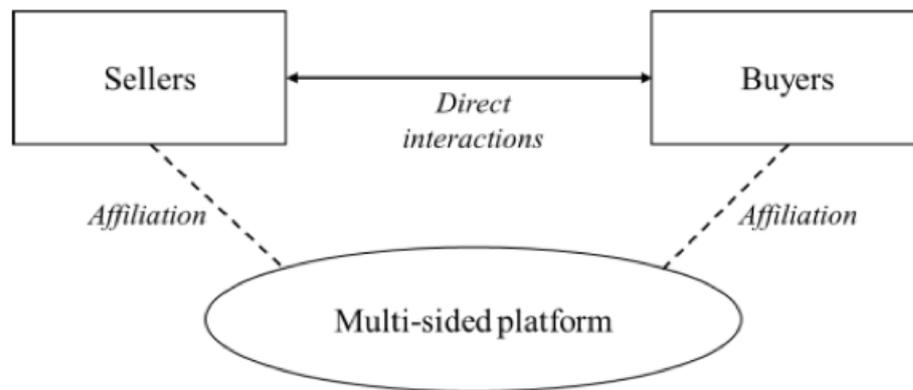
# Capitolo 1

## MULTI-SIDED PLATFORM

### 1.1 Definizione

Le *multi-sided platform* (MSP) vengono chiamate anche *piattaforme multiversante*, in quanto fungono da intermediazione tra due o più parti di un mercato, generalmente tra venditore e consumatore (Rochet et al., 2003). L'obiettivo su cui si fonda una piattaforma è quello di creare una infrastruttura aperta dove gli utenti interagiscono tra di loro in modo da semplificare gli scambi di beni e servizi, consentendo la creazione di valore per tutti i componenti (Figura 1.1).

Tale tipologia di piattaforma è particolarmente diffusa nel settore dell'*Information Technology* e sta svolgendo un ruolo sempre più importante nell'economia globale del XXI secolo.



**Figura 1.1** Struttura di una piattaforma multiversante. Fonte: Houtari Pontus (2017). “Too Big to Fail? Overcrowding a Multi-Sided Platform and Sustained Competitive Advantage”.

Si possono distinguere in (Evans, 2011):

- *Piattaforme di scambio* o *exchanges*, sono quelle piattaforme che aiutano i due versanti del mercato, consumatori e venditori, a raggiungere un match, quindi un accordo tra le due parti. Ebay è una di queste piattaforme dato che non produce il prodotto ma funge da intermediario tra individui.
- *Piattaforme basate su meccanismi pubblicitari* o *advertising-supported media*, sono piattaforme multi-versanti supportate economicamente anche dalla pubblicità. Sky rappresenta appieno questa categoria in quanto produce o acquisisce contenuti (film

o eventi sportivi), che distribuisce ai clienti, ma contemporaneamente usufruisce del sostegno pubblicitario.

- *Sistemi di transazione*, consideriamo il leader mondiale nel mercato delle carte di credito e di debito, VISA. Tale piattaforma consta di due elementi: da una parte il consumatore che prediligerà la carta di credito a discapito della storica moneta e dall'altra parte i negozianti che accettano tale tipo di pagamento.
- *Software platforms*, sono piattaforme che forniscono servizi per gli sviluppatori di applicazioni (Android e IOS).

I vantaggi principali della piattaforma sono (*Fernàndez-Maciàs, 2018*):

- Accesso alle informazioni attraverso l'acquisizione e l'elaborazione dei *big data*.
- Flessibilità della produzione attraverso lo sfruttamento di algoritmi.
- *Zero marginal cost*, associato al costo della produzione di una unità addizionale prodotta.
- *Esternalità di rete* o *network effects*.

Il ruolo della piattaforma è quello di *matchmaker* tra i due o più versanti del mercato. Ad esempio, la piattaforma Uber è nata nel momento in cui i fondatori hanno individuato una domanda inesausta nel settore del trasporto privato. Il sistema dei taxi è un sistema fortemente regolamentato caratterizzato da elevate barriere all'entrata, come l'ottenimento della licenza taxi. Infatti, lo scopo di Uber, e quello delle piattaforme in generale, è quello di permettere uno scambio laddove il mercato non permette di raggiungere una struttura efficiente.

Tuttavia, l'innovazione introdotta da queste piattaforme sul mercato ha provocato *effetti negativi e distruttivi* sui segmenti di mercato in cui operano. L'esponentiale potere di mercato, ottenuto in un intervallo di tempo breve dalle piattaforme, determina l'uscita dal mercato dei competitor storici.

## 1.2 Big Data

Uno dei principali drivers di crescita delle piattaforme è l'analisi e lo sfruttamento dei *Big Data*.

Il termine *Big Data* ("grandi [masse di] dati" in inglese) indica un grande volume di dati informativi che, attraverso l'uso di strumenti informatici (quali algoritmi), si è in grado di analizzare ed estrarre valore dai dati stessi (*De Mauro et al., 2012*). Il possesso dei dati conferisce e garantisce potere di mercato, in quanto l'utilizzo e lo sfruttamento di informazioni può essere un valore aggiunto per la piattaforma.

Esiste una classificazione dei dati (*Information Commissioner's office, 2017*):

- Dati volontari: sono registrati volontariamente dall'individuo (nome, numero telefonico, data di nascita, indirizzo...)
- Dati osservati: sono registrati automaticamente (IP Address, sistema operativo, velocità del click, search history, like sui social network...)
- Dati derivati: sono prodotti da altri dati.
- Dati inferenziali: sono prodotti attraverso un complesso metodo di analisi per ricercare correlazioni tra diversi dataset (reddito, profilo di rischio, comportamenti, ideologia politica...)

Va precisato che non tutti i dati sono fondamentali; alcuni di essi mantengono lo stesso valore nel tempo a differenza di altri (ad esempio le informazioni sui comportamenti dei consumatori variano nel tempo).

Di seguito sono elencate le caratteristiche dei dati (*De Long et al., 1997*):

- Beni non rivali. Si è discusso di non rivalità dei dati nel momento in cui si definiscono i beni pubblici. L'utilizzo del dato è pubblico una volta che esso viene prodotto.
- Costi di collezione del dato. Il costo marginale di raccolta del dato è approssimativamente pari a zero. Questo si verifica quando viene utilizzato un dato (ad esempio la visualizzazione di un film sulla piattaforma Netflix) e l'impresa che ha rilasciato quel dato ottiene ulteriori informazioni sui comportamenti e sulle preferenze del consumatore (l'algoritmo di suggerimento è in grado di individuare le preferenze del consumatore mappando i dati storici del cliente).
- Gestione del dato. Per gestire una mole ingente di dati, la piattaforma deve costruire una infrastruttura di database in grado di contenere i *big data*. Una volta messa in piedi l'infrastruttura, maggiori saranno i dati elaborati, minori saranno i costi. In questo caso si parlerà di economie di Scala (volume) e di Scopo (varietà dell'informazione).
- Feedback derivanti dai comportamenti dei consumatori, che possono essere monetizzati. Effettuando una specifica ricerca, nelle altre pagine web risulteranno dei banner con offerte sulla ricerca eseguita e con un semplice clic su una di queste pubblicità qualcuno guadagnerà.

Le suddette caratteristiche ci introducono in un mercato non perfetto, caratterizzato da una struttura molto concentrata (poche imprese che forniscono beni o servizi, come Amazon e Google).

In tale contesto, i dati vengono definiti come *asset essenziali* o *essential facilities* (Graef, 2019). Dal punto di vista giuridico, una impresa che gestisce una infrastruttura o degli *asset essenziali*, deve metterli a disposizione della collettività ad un prezzo dettato dal mercato e non dall'impresa stessa, altrimenti si parla di abuso di posizione dominante. Ad esempio, l'azienda che è in grado di gestire questi dati ed è integrata a valle, ha il potere di escludere i rivali innalzando successivamente il prezzo. In tal caso, parlando di *big data*, non si farà più riferimento al prezzo del dato ma all'accesso e alla condivisione pubblica dello stesso (*mandatory sharing*). Tuttavia, con la condivisione dei dati sarà difficile, se non addirittura impossibile garantire la privacy dei dati sensibili dei consumatori.

### 1.3 Esternalità di rete

Le *esternalità di rete* o *network effects* sono un fenomeno economico alla base della diffusione delle piattaforme (Houtari, 2017). Un prodotto mostra *esternalità di rete* quando il suo valore per un individuo dipende dal numero di altri utenti (Shapiro, 1999).

Le *esternalità di rete* possono essere dirette e indirette. Nel primo caso sono generate nel momento in cui un aumentato utilizzo del bene o del servizio determina un maggiore valore dello stesso per gli altri utenti; nel secondo caso, invece, sono prodotte da beni e servizi complementari che portano a un maggior valore del bene o servizio originario.

Per le piattaforme, tratteremo di un caso particolare di *esternalità di rete: incrociata* o *cross-platform network effect*. Questo fenomeno si verifica quando le decisioni prese dagli individui appartenenti ad un versante del mercato producono effetti sugli agenti che appartengono all'altro versante. Quando si genera una *esternalità di rete incrociata*, il valore di un prodotto o di un servizio aumenta in base al numero degli utenti: maggiore è il numero di utenti (consumatori o clienti) che vorranno usufruire del servizio o del prodotto della piattaforma, maggiore sarà il numero di produttori (venditori) che vorranno far parte della piattaforma.

Difatti il successo delle piattaforme è dovuto al focus su entrambi i versanti del mercato.

## 1.4 Pricing Strategy

Per comprendere le strategie di prezzo si farà riferimento dapprima al *modello di Bertrand* (Benchmark e Realistico) e successivamente al *modello di Rochet-Tirole*.

### 1.4.1 Modello di Bertrand - Benchmark

Consideriamo una piattaforma monopolista avente due lati del mercato, lato 1 e lato 2, e si concorre sui prezzi. Assumiamo dapprima che la piattaforma fissi il prezzo su un lato senza osservare ed essere influenzato dall'altro lato. Le variabili del modello sono:

- $p_1$  e  $p_2$ , i prezzi applicati sul primo e sul secondo versante.
- $q_1$  e  $q_2$ , le quantità offerte sul primo e sul secondo versante.
- $D(p_1)$  e  $D(p_2)$ , le funzioni di domanda del primo e del secondo versante in funzione dei prezzi.
- $e_{21}$ , l'*esternalità di rete* che il gruppo 2 genera nei confronti del gruppo 1, ossia il beneficio che si ottiene osservando l'altro gruppo e che ha un effetto positivo. Quindi maggiore sarà la domanda sul secondo versante, maggiore sarà la domanda sul primo lato, avente così un effetto positivo, ovvero di espansione. Speculare è la definizione di  $e_{12}$ .

$$\begin{aligned} D(p_1) &= 1 - p_1 & D(p_2) &= 1 - p_2 \\ q_1 &= 1 + e_{21}D(p_2) - p_1 & q_2 &= 1 + e_{12}D(p_1) - p_2 \end{aligned}$$

Ipotizziamo che le esternalità siano positive e costanti con costi nulli. Se il prezzo  $p_2$  si riduce, la domanda sullo stesso versante aumenta e questo comporta l'aumento anche della domanda sul lato 1. Quindi c'è un effetto di *esternalità incrociata*.

La piattaforma massimizza i ricavi sul primo lato del mercato, e accade la stessa cosa anche per il secondo lato.

$$\begin{aligned} \text{Max } p_1 \pi_1 &= p_1(1 + e_{21}D(p_2) - p_1) \\ \text{Max } p_2 \pi_2 &= p_2(1 + e_{12}D(p_1) - p_2) \end{aligned}$$

Ottimizzando attraverso la derivata del profitto rispetto al prezzo avremo:

$$\begin{aligned} p_1^{ind} &= \frac{2 + e_{21}(1 - e_{12})}{4 - e_{12}e_{21}} & p_2^{ind} &= \frac{2 + e_{12}(1 - e_{21})}{4 - e_{12}e_{21}} \\ \pi_1^{ind} &= \frac{(2 + e_{21}(1 - e_{12}))^2}{(4 - e_{12}e_{21})^2} & \pi_2^{ind} &= \frac{(2 + e_{12}(1 - e_{21}))^2}{(4 - e_{12}e_{21})^2} \end{aligned}$$

In conclusione, il prezzo sul lato 1 del mercato è:

- Inversamente proporzionale alle esternalità che quel lato dà all'altro  $e_{12}$ .
- Linearmente proporzionale alle esternalità che riceve dall'altro lato  $e_{21}$ .

#### 1.4.2 Modello di Bertrand - Realistico

Ora consideriamo un modello in cui la piattaforma più avvedutamente, operando sui due lati del mercato, massimizzerà il profitto aggregato.

$$\pi_{agg}(p_1; p_2) = \pi_1 + \pi_2 = p_1 q_1 + p_2 q_2$$

La differenza tra il *modello Benchmark* e il *modello Realistico* è che, nel momento in cui si massimizzerà il profitto aggregato  $\pi_{agg}$  del secondo modello per uno dei due prezzi, avremo entrambe le componenti derivate  $p_1 q_1$  e  $p_2 q_2$  che non erano presenti nel primo. Le suddette componenti misurano quanto la variazione del prezzo su un lato impatti sulla redditività dell'altro lato del mercato.

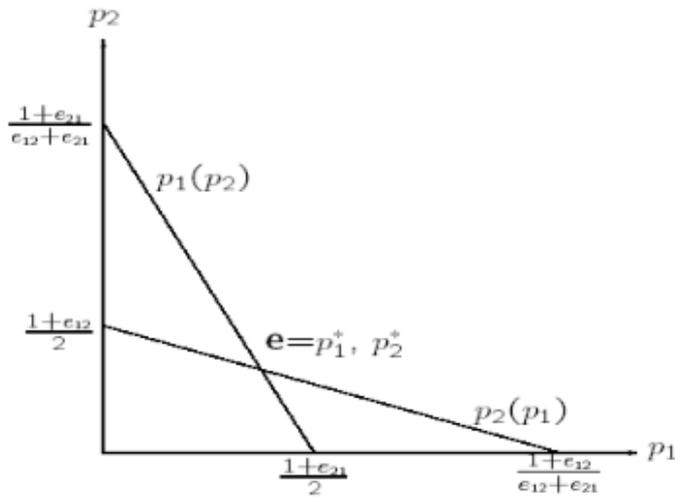
Ciò che si ottiene dalla massimizzazione del profitto è:

$$\begin{cases} p_1(p_2) = \frac{1 + e_{21} - p_2(e_{21} + e_{12})}{2} \\ p_2(p_1) = \frac{1 + e_{12} - p_1(e_{12} + e_{21})}{2} \end{cases}$$

$$p_1^* = \frac{1 - e_{12}}{2 - (e_{12} + e_{21})} \quad p_2^* = \frac{1 - e_{21}}{2 - (e_{12} + e_{21})} \quad \pi_2^* = \frac{1 - e_{12} e_{21}}{2 - (e_{12} + e_{21})}$$

Quindi, dai risultati ottenuti si osserva un effetto di bilanciamento tra i due versanti (detto anche *water bed effect*): l'aumento del prezzo su di un lato comporta la riduzione del prezzo sull'altro lato. Per tale motivo la piattaforma, operando su vari versanti del mercato, propone prezzi differenti: prezzo minore nei casi in cui le *esternalità di rete* siano maggiori (consumatori); prezzo maggiore nell'altro versante del mercato (venditori). Perciò le strategie di prezzo risentono fortemente dell'*esternalità di rete* che ogni gruppo genera.

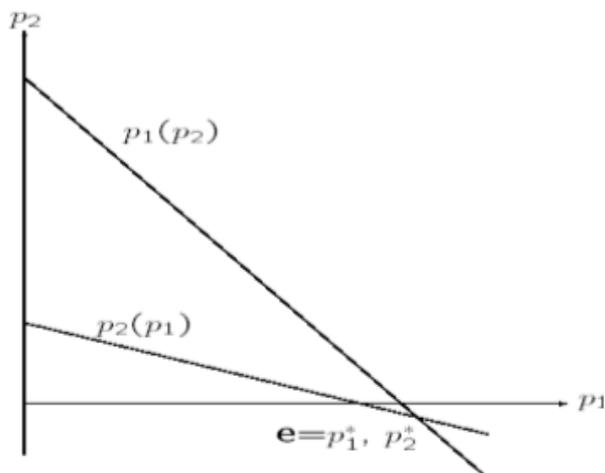
Immaginiamo di avere dei livelli di esternalità indiretta intermedi. Ad esempio, se  $e_{12} = e_{21}$ , graficamente (Figura 1.2) avremo una composizione delle funzioni di reazione tali per cui tutte e due i lati del mercato pagheranno un prezzo positivo.



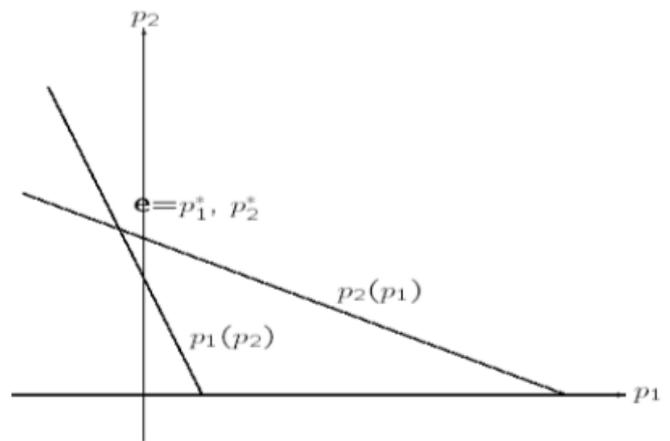
**Figura 1.2** Caso di esternalità di rete indiretta neutra

Nel caso in cui  $e_{21} > e_{12}$  (Figura 1.3), la piattaforma fisserà un prezzo positivo nel gruppo 1, ma al contempo un prezzo negativo nel gruppo 2, in quanto il secondo gruppo genererà maggiori benefici sull'altro versante. L'idea di business è quella di pagare i membri del secondo gruppo attraverso buoni o coupon affinché si abbia un effetto di attrazione sull'altro lato.

Speculare è il caso in cui  $e_{12} > e_{21}$  (Figura 1.4).



**Figura 1.4** Caso in cui  $e_{21} > e_{12}$



**Figura 1.3** Caso in cui  $e_{12} > e_{21}$

Quindi, in presenza di una piattaforma, si verifica una forma di *sussidiazione incrociata* che non ha finalità escludenti: il lato sussidiato genererà maggiori benefici sull'altro che, dal suo canto, pagherà un prezzo maggiore.

Dall'analisi dei due modelli si può concludere che il monopolio sul mercato di una piattaforma integrata potrebbe addirittura portare ad un maggiore profitto e surplus del consumatore.

Inoltre, la somma dei prezzi sarà inferiore rispetto a quella della piattaforma non integrata:

$$p_1^* + p_2^* = 1 \quad p_1^{ind} + p_2^{ind} = 1 + \frac{e_{12} + e_{21}(1 - e_{12})}{4 - e_{12}e_{21}} > 1$$

### 1.4.3 Modello di Rochet-Tirole

Nel paper "Platform competition in two-sided markets", i due ricercatori hanno studiato il mercato a due versanti delle carte di credito, analizzando l'elasticità della domanda (Rochet and Tirole., 2003).

Consideriamo una piattaforma che gestisce i due lati del mercato. Il profitto sarà dato dalla seguente formula:

$$\pi = (p^c + p^m - c)D^m(p^m)D^c(p^c)$$

Le diverse variabili del modello sono:

- $p^c$ , prezzo per i consumatori.
- $p^m$ , prezzo per i commercianti.
- $c$ , costi marginali della piattaforma.
- $(p^c + p^m - c)$ , il markup o ricavo unitario della piattaforma.
- $D^m(p^m)D^c(p^c)$  la domanda complessiva del mercato data dal prodotto della domanda dei consumatori e quella dei commercianti. La moltiplicazione delle funzioni di domanda rappresenta l'ammontare complessivo delle transazioni che si possono originare in un mercato.

Ottimizzando il profitto aggregato, rispetto al lato dei consumatori e dei commercianti, avremo che:

$$\frac{d\pi}{dp^c} = 0 \quad \frac{d\pi}{dp^m} = 0$$

Troviamo:

$$p^c + p^m - c = \frac{p^c}{\varepsilon^c} = \frac{p^m}{\varepsilon^m}$$

Ma possiamo riscrivere la formula come:

$$\frac{p^c - (c - p^m)}{p^c} = \frac{1}{\varepsilon^c} \quad \frac{p^m - (c - p^c)}{p^m} = \frac{1}{\varepsilon^c}$$

I risultati ottenuti dai due studiosi sono simili all'indice di Lerner. Tuttavia, è evidente una differenza sostanziale: mentre nel modello di Lerner è presente il prezzo del singolo prodotto, in quello di Rochet-Tirole avremo la somma dei prezzi dei prodotti dei due lati del mercato.

Nel versante del mercato in cui la domanda è inelastica, l'elasticità tende a zero e il markup sarà più elevato.

La differenza  $(c - p^m)$  rappresenta l'ammontare a cui va incontro l'impresa per coprire i costi, una volta incassato il prezzo dall'altro lato; quindi si tratta di una sorta di *costo opportunità*.

Come già accennato precedentemente, in presenza di una piattaforma, è prevista una *sussidiazione incrociata* da un lato all'altro, ma Rochet-Tirole aggiungono alla trattazione anche il concetto di elasticità della domanda. Infatti, secondo Rochet-Tirole, i fattori principali che influenzano il prezzo nel mercato a due versanti sono sia l'esternalità di rete che l'elasticità di domanda.

In conclusione, i ricercatori affermano che:

- Il lato che è sussidiato è quello che genera maggiori benefici sull'altro ed avrà una domanda più elastica.
- Il lato che pagherà è quello che riceverà più benefici ed avrà una domanda rigida.

Un caso interessante da analizzare è l'ingresso delle piattaforme nel mercato del payment card industry. Considerando la piattaforma American Express (AMEX), i proprietari di carta di credito pagheranno una quota fissa o mensile molto bassa per poter usufruire della stessa, a differenza dei commercianti che, ad ogni transazione, pagheranno una percentuale sul bene venduto. In sintesi, si avrà che il circuito AMEX fissa i prezzi sui due lati del mercato (ZhuWhang, 2016).

### 1.5 Il dilemma del “Winner Take It All Dynamics”

I mercati in cui le piattaforme operano hanno un elemento particolare in comune: il *winner take it all*, ovvero il “vincitore prende tutto il mercato” (Eisenmann Thomas R., 2006; SunMingchun et al., 2007). Ad esempio, negli ultimi 20 anni, Google è diventato monopolista nella ricerca online. Questo perché il vincitore, aumentando le dimensioni,

permette di internalizzare gli effetti sui prezzi e l'espansione permette di ottenere benefici per tutti i partecipanti all'infrastruttura della piattaforma.

La struttura di *winner takes it all* emerge nel momento in cui si hanno i seguenti elementi base:

- Costi di *multi-homing* (Armstrong, 2006). Nel caso in cui i prezzi e la qualità dell'offerta sono percepiti come variabili, gli utenti possono iscriversi a diverse piattaforme (fenomeno di *multi-homing*). Se una piattaforma è in grado di coprire la maggior parte delle esigenze dei clienti ad un prezzo competitivo, il passaggio da una piattaforma all'altra diventa meno probabile (Wirtz et al., 2019). Questa condizione implica dei costi associati al *multi-homing*, comprendenti tutte le spese che gli utenti sostengono per stabilire l'affiliazione alla singola piattaforma (Wikipedia). In presenza di costi elevati di *multi-homing*, gli utenti sceglieranno la piattaforma più efficiente a discapito delle altre.
- Esternalità di rete positive. Come abbiamo detto precedentemente, le esternalità di rete sono un fenomeno alla base della diffusione delle piattaforme. La piattaforma, sfruttando le esternalità di rete dirette, indirette e trasversali, si garantisce maggiori quote di mercato in cui essa opera, diventando in tal modo monopolista.
- Strategie di differenziazione. La capacità dell'impresa di offrire un prodotto unico, dotato di caratteristiche non presenti in altri prodotti, consente di ottenere un vantaggio competitivo. Se il prodotto è omogeneo è più difficile avere un *winner take it all*: il consumatore sceglierà la piattaforma che offre caratteristiche uniche del prodotto o servizio. Un esempio calzante è quello di Pagine Gialle, tipologia di elenco telefonico molto diffuso e utilizzato all'inizio del XXI secolo, che non avendo una differenziazione del prodotto, non è stata in grado di essere un *winner take it all*.

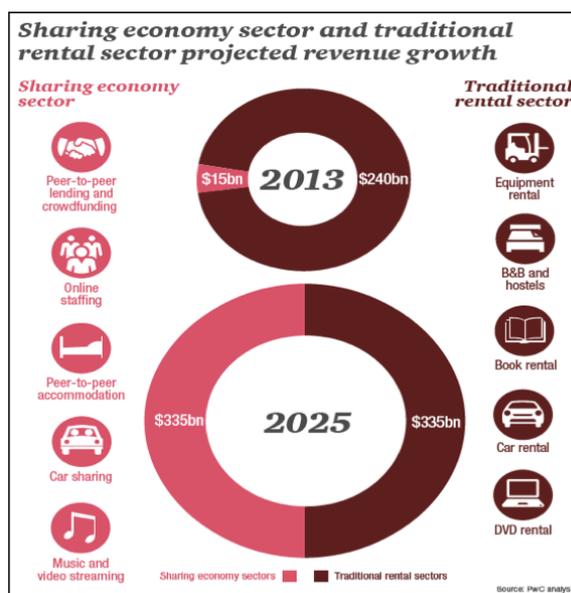
### 1.6 Sharing economy

La *sharing economy* o "economia della condivisione" si basa sul concetto economico delle *piattaforme multi-versante* e delle *esternalità di rete* (Koen Frenken et al., 2019).

Questo tipo di economia promuove forme di consumo più razionali, basate sul riutilizzo di beni in comunità, traendone valore rispetto alla proprietà esclusiva. In grado di applicarsi a diversi settori (dai trasporti al turismo, dalla finanza collaborativa ai servizi domestici e professionali on-demand), la *sharing economy* basa la sua diffusione nell'evoluzione

socioculturale. I tre elementi essenziali per il funzionamento del modello sono: condivisione, relazione e fiducia.

In termini economici, oggi giorno, la *sharing economy* è una realtà caratterizzata da una crescita vertiginosa anche se al momento rappresenta solo una modesta percentuale del PIL mondiale. Tuttavia, secondo una ricerca svolta nel 2015 dalla compagnia PricewaterhouseCoopers (Ádám Osztoivits et al., 2015), i ricavi complessivi delle piattaforme *sharing economy* passeranno, entro il 2025, da 15 bn \$ a 335 bn \$. In Figura 1.5, possiamo notare come il mercato della *sharing economy* sia in piena espansione rispetto al mercato tradizionale, la cui crescita è abbastanza lenta. La condivisione e il noleggio sono parte integrante del tessuto sociale ed economico e, di fatto, la *sharing economy* si basa su queste attività economiche. Tuttavia, la condivisione nel passato avveniva tra pochi soggetti, i quali nutrivano legami di amicizia e rapporti di fiducia ed erano per lo più limitati ad accordi stretti di persona. La condivisione su larga scala in cui avviene la condivisione è la novità introdotta dalla *sharing economy*, interessando persone senza alcun legame affettivo, ma che utilizzano le tecnologie digitali.



**Figura 1.5** Prospettive di crescita della Sharing Economy. Fonte: Ádám Osztoivits et al., (2015). “Sharing or paring? Growth of the sharing economy”.

Una delle prime forme della “economia di condivisione” è stato il rapporto *peer to peer* (P2P) o *consumer to consumer* (C2C), cioè il rapporto diretto tra i membri della comunità attraverso l’uso della piattaforma. L’utente non si limita più al ruolo passivo di consumatore, ma partecipa attivamente alla fase di offerta dei propri beni non utilizzati, diventando a sua volta un produttore (figura del *prosumer*). Eppure, negli ultimi anni, si è diffuso un nuovo

modello di relazione nella *sharing economy*: il fenomeno del *business to consumer*. In tal caso, il fornitore del servizio non è più un consumatore, ma è un soggetto professionale (una impresa) che offre beni o servizi ai consumatori finali. Le piattaforme oltre ad avere una funzione di *matchmaker*, come abbiamo definito nei paragrafi precedenti, ha anche altre funzioni come quella di regolatore e sistemi di controllo. In molti casi le piattaforme più grandi, come Uber e Airbnb, introducono un sistema di feedback e di rating, che comporta la riduzione di asimmetrie informative tra i due gruppi del mercato. Oltretutto, queste piattaforme introducono un sistema di controllo, per monitorare che il bene o il servizio offerti dal venditore siano effettivamente quelli proposti, e un sistema di protezione dell'acquirente attraverso il rimborso dell'intero prezzo di acquisto, nei casi in cui l'oggetto non corrisponda alla descrizione o venga smarrito nel trasporto. Tali soluzioni sono state introdotte per eliminare la barriera di diffidenza nel condividere beni tra individui che non si conoscono e, quindi, aumentare la fiducia che si pone alla base di ogni tipo di rapporto all'interno della *sharing economy*.

#### 1.6.1 Fattori di crescita

I drivers principali di crescita della “economia di condivisione” possono essere riconducibili a diversi fattori. L'elenco sottostante è il sunto di tutti gli elementi che hanno permesso l'affermazione, nel panorama mondiale, della *sharing economy*:

- La diffusione e la crescente facilità di accesso ad internet hanno permesso la nascita e la successiva espansione della *sharing economy*. Attraverso l'uso di dispositivi mobili collegati ad internet è stato possibile azzerare le distanze tra compratori e venditori.
- La disponibilità di risorse inutilizzate ha favorito lo sviluppo delle piattaforme *sharing*. Negli ultimi anni sulla scena economica si è assistito ad una evoluzione concettuale dell'economia: da quella del possesso a quella dell'accesso. Infatti, in passato, gli individui preferivano possedere i beni che usufruivano ma il loro utilizzo diminuiva con l'avanzare del tempo (ad esempio obsolescenza). Ciò determina un accumulo di beni inutilizzati, anche se ancora utilizzabili. In tale scenario emergono le piattaforme *sharing*, le quali possono fungere da intermediari fra colui che ha una risorsa inutilizzata e chi è alla ricerca della stessa. Nel caso in cui non fosse disponibile la piattaforma, si avrebbe un elevato costo di transazione e quindi si andrebbe incontro a una frizione del mercato (domanda inevasa). In conclusione, si

può affermare che le piattaforme emergono qualora ci siano elevati costi di transazione (Felländer et al., 2015), oppure in mercati dove la domanda è instabile o ancora in mercati regolamentati. Non necessariamente si tratta di mercati giganteschi; in molti casi abbiamo piattaforme che operano in un mercato ristretto (ad esempio TaskRabbit).

- Le piattaforme servono mercati tipicamente locali ma, attraverso l'uso di internet, riescono ad aggregarli così offrendo una maggiore interazione tra gli individui.
- La questione ambientale è, ad oggi, oggetto di dibattito acceso tra le organizzazioni politiche mondiali. In un contesto di attenzione alle tematiche ambientali senza precedenti, attestate da un crescente sentimento di tutela ambientale, la *sharing economy* è percepita come un fenomeno economico eco-sostenibile con un impatto ambientale ridotto rispetto ad altri fenomeni economici.

### 1.6.2 Modelli di platform sharing

Nella ricerca accademica condotta da Constantiou, Marton e Tuunainen (2017) vengono distinti quattro modelli di *sharing platform*: Franchiser, Principal, Chaperone e Gardener. Ogni modello è in funzione sia del livello di controllo, esercitato dalla piattaforma sui partecipanti, e sia del livello di rivalità presente tra di essi. I quattro modelli possono essere raffigurati mediante una matrice, dove sull'asse delle ordinate viene posta la rivalità e sull'asse delle ascisse il controllo (Figura 1.6).

		Control	
		Loose Minimum standards or guiding principles for platform participation are set by the platform owner	Tight Platform participation is specified, standardized and monitored by the platform owner
Rivalry	High Pricing scheme based on real-time changes in supply and demand	<b>Chaperones</b> Prototypical Example: <b>Airbnb</b> <ul style="list-style-type: none"> <li>• Value proposition: Service differentiation</li> <li>• Other examples: Homeaway, Rentomo, Apprentus</li> </ul>	<b>Franchisers</b> Prototypical Example: <b>Uber</b> <ul style="list-style-type: none"> <li>• Value proposition: Low costs and efficiency gains</li> <li>• Other examples: Lyft, Postmates, Caviar</li> </ul>
	Low Pricing scheme based on compensation of the suppliers' costs	<b>Gardeners</b> Prototypical Example: <b>Couchsurfing</b> <ul style="list-style-type: none"> <li>• Value proposition: Self-organization and community building</li> <li>• Other examples: BeWelcome, BlaBlaCar, Peerby</li> </ul>	<b>Principals</b> Prototypical Example: <b>Handy</b> <ul style="list-style-type: none"> <li>• Value proposition: Low costs and risk mitigation</li> <li>• Other examples: TaskRabbit, Zeel, Deliveroo</li> </ul>

Figura 1.6 Modelli sharing platform

A destra della matrice ritroviamo i modelli Franchiser, come Uber, e Principals, come Handy o Taskrabbit, i quali esercitano un severo controllo sui partecipanti della piattaforma, standardizzando tutte le procedure di verifica e transazione. Essi differiscono tra loro in quanto i Principal favoriscono una bassa rivalità tra i partecipanti, applicando prezzi standard per i servizi acquisti, mentre i Franchiser sono caratterizzati da una maggiore rivalità in quanto il prezzo del servizio è imposto ed è in funzione dei picchi della domanda.

Per quanto riguarda il lato sinistro della matrice, i Gardener, come Couchsurfing, e i Chaperone, come Airbnb, esercitano un controllo meno stringente sui partecipanti della piattaforma, stabilendo norme sociali e valori comunitari. La differenza tra questi due modelli si ravvisa nella rivalità tra i partecipanti, che è maggiore nel modello Chaperones a causa dei prezzi raccomandati dalla piattaforma sulla base della domanda, mentre è minore per i Gardeners, in cui lo schema di prezzo è deciso dai venditori.

## Capitolo 2

### AIRBNB

#### 2.1 La storia

La storia di Airbnb inizia alla fine del 2007 a San Francisco, quando due ragazzi neolaureati, in difficoltà economiche, decisero di affittare dei posti letto nella propria casa, durante il meeting dell'*Industrial Designers Society of America* (IDSA) (Guttentag, 2013).

Fondata nel 1965, la IDSA è una delle più antiche e grandi associazioni di design industriale americana. I due ragazzi compresero l'importanza dell'evento e intravidero l'opportunità di guadagnare, in quanto gli hotel della città avevano terminato le camere.

Non avendo molti soldi a disposizione, decisero di comprare tre materassini gonfiabili sistemandoli in una stanza libera della propria abitazione e offrire anche la colazione al mattino seguente.

Su un sito internet creato ad-hoc, "airbedandbreakfast.com", fu pubblicato l'annuncio nel quale erano state inserite delle foto della camera e una breve descrizione dei servizi offerti. L'idea fu un successo tale che spronò i ragazzi a organizzare conferenze per pubblicizzare il loro progetto e incentivare le persone a rendere disponibili le proprie case o le stanze inutilizzate. Spinto dalle potenzialità dell'idea, il programmatore informatico Nathan Blecharczyk si unì al gruppo di amici e insieme lavorarono per modificare il sito originale e renderlo più appetibile; ciononostante, la partecipazione sulla piattaforma fu davvero scarsa e i ricavi nulli.

La grande occasione si presentò nell'estate del 2008 durante il convegno democratico di Barack Obama a Denver. Per finanziare il sito "airbedandbreakfast.com", durante la convention, i tre fondatori crearono e vendettero delle speciali scatole di cereali per la prima colazione, che riportavano le caricature dei candidati Barack Obama e John McCain. In seguito, il nome del sito fu abbreviato nel più conveniente airbnb.com (Figura 2.1).



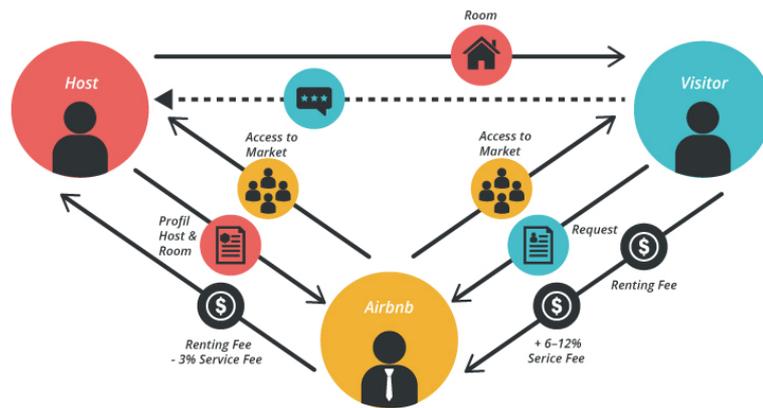
**Figura 2.1** Airbnb logo. Fonte: <https://money.cnn.com/gallery/news/2015/09/03/logo-changes-public-outrage/7.html>

Anche se la trovata pubblicitaria aumentò l’appeal aziendale, i guadagni della loro attività erano ancora troppo esigui. Interfacendosi con la comunità Gebbia, Chesky e Blecharczyk intuirono che il problema principale era relativo alla qualità mediocre delle foto scattate dagli host. La soluzione, quindi, fu quella di ingaggiare fotografi professionisti per migliorare gli scatti di appartamenti o stanze da affittare, che sarebbero stati poi pubblicati nei post. Il successo fu immediato: la crescita dell’impresa fu esponenziale, contando più di 6000 impiegati e un fatturato maggiore di 2,6 miliardi di dollari. Ad oggi, Airbnb è la piattaforma di “vacation rental online marketplace” più usata al mondo.

## 2.2 Cosa è e come funziona?

Il business model di Airbnb riprende le caratteristiche di una piattaforma descritte nel primo capitolo: far comunicare i due versanti del mercato, cioè gli host (venditori) con i guest (acquirenti), imponendo una commissione differente sulla transazione tra i due soggetti economici.

In sostanza, Airbnb è una *sharing platform* ideata per tutte le tipologie di viaggio che permette agli host di inserire un annuncio della loro casa o stanza e metterli in contatto con i guest che desiderano affittarla (Figura 2.2). Generalmente, la piattaforma applica una commissione per l’affittuario, che può variare dal 6% al 12%, e una commissione del 3% per chi propone il suo appartamento/stanza (Guttentag, 2013).



**Figura 2.2** Business model di Airbnb. Fonte: <https://bmttoolbox.net/stories/airbnb/>

Chiunque può offrire la propria casa o stanza ad un determinato prezzo, eseguendo l'iscrizione sul sito. Tale processo prevede una serie di step in cui vengono inserite le generalità richieste dalla piattaforma (nome, cognome, indirizzo, e-mail, etc.) con lo scopo di poter effettuare controlli sulla identità dell'host. Una volta terminata l'iscrizione, l'utente può pubblicare l'annuncio dell'affitto in questione, il cui contenuto dovrà riportare una descrizione dettagliata dell'alloggio (comprendente sia una galleria fotografica che i servizi offerti) e il prezzo richiesto.

A loro volta, gli ospiti cercheranno la soluzione più consona alle loro esigenze (decidendo la città o il quartiere dove vorranno soggiornare) e potranno contattare privatamente l'host per ottenere maggiori informazioni. In seguito alla prenotazione dell'alloggio, non è la piattaforma, ma l'host a decidere se accettare o meno la richiesta di affitto.

Il processo non si conclude con l'avvenuta transazione tra i due versanti del mercato, ma con la piattaforma che incentiva i suoi utenti a inserire una recensione o un feedback dell'esperienza vissuta.

La *mission* di Airbnb è quella di contribuire a creare un mondo in cui per "casa" non si intende il posto fisico in cui si vive ma un sentirsi a proprio agio ovunque ci si trovi. In sintesi, *Jeroen Oskam et al.* (2016) hanno evidenziato alcuni drivers di crescita di Airbnb:

- Pubblicità forte e incisiva: "Live like a local".
- Facilità di accesso e creazione di un mercato di fiducia attraverso la relazione P2P.
- Potenzialità della rete, che determina crescenti vantaggi di scala.

Come altre piattaforme digitali, Airbnb rientra tra le *exponential organizations* (*Ismail et al.*, 2014). La digitalizzazione ha permesso alle organizzazioni di andare ben oltre i mercati tradizionali, dati i costi marginali minori. Le *exponential organizations* sono aziende che

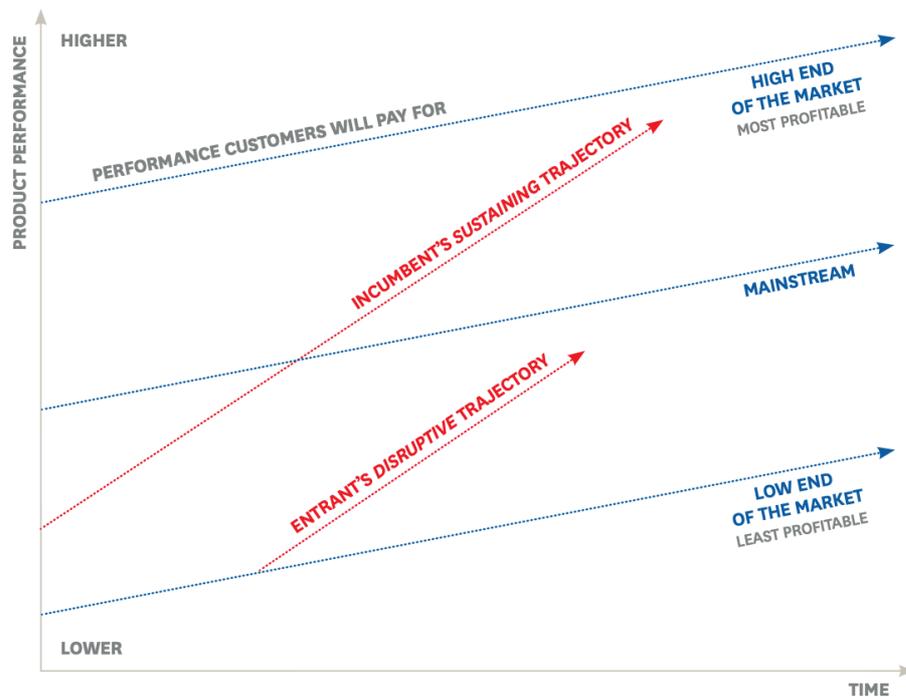
hanno il coraggio di sperimentare: utilizzano interfacce smart e minimali, si basano sulla community e gestiscono algoritmi.

### 2.3 Disruptive innovation theory

La *Disruptive innovation theory* è stata introdotta nel 1995 da *Christensen et al.* e ristampata nel 2015. La teoria descrive come una piccola impresa, dotata di risorse limitate, possa rivoluzionare il mercato in cui essa opera attraverso l'introduzione di un prodotto o un servizio innovativo. Generalmente, quando un settore è maturo, le aziende storiche concentrano gli sforzi sui propri prodotti e servizi presenti già sul mercato, migliorandoli e perfezionandoli, al fine di soddisfare le richieste dei consumatori più esigenti e con più alta propensione di spesa. Attraverso le analisi di mercato, i nuovi operatori identificano dei segmenti di mercati poco serviti dalle imprese storiche e sviluppano prodotti o servizi innovativi. Questo scenario è definito *disruptive* in quanto gli entranti possono accedere al mercato principale minacciando le aziende leader.

Dal punto di vista temporale, il passaggio dal vecchio al nuovo mercato avviene lentamente. Durante le prime fasi di sviluppo, il nuovo prodotto è inferiore rispetto ai prodotti della concorrenza già immessi sul mercato. Tuttavia, nel momento in cui la qualità sarà cresciuta abbastanza da soddisfare il mercato di massa, il prodotto sarà in grado di ottenere quote di mercato consistenti. In Figura 2.3, *Christensen et al.* (2015) pone sugli assi il tempo e le performance di prodotto, e suddivide i consumatori in tre gruppi:

- *Low end of the market*: segmento di mercato meno profittevole per un'impresa in quanto i consumatori hanno una minore predisposizione a spendere e non sono interessati alle performance dei prodotti.
- *Main stream* o mercato di massa: si raggiunge quando le specifiche del prodotto sono accettate dalla maggioranza dei consumatori.
- *High end of the market*: segmento di mercato più ricercato dalle imprese poiché i consumatori hanno una maggiore predisposizione a spendere.

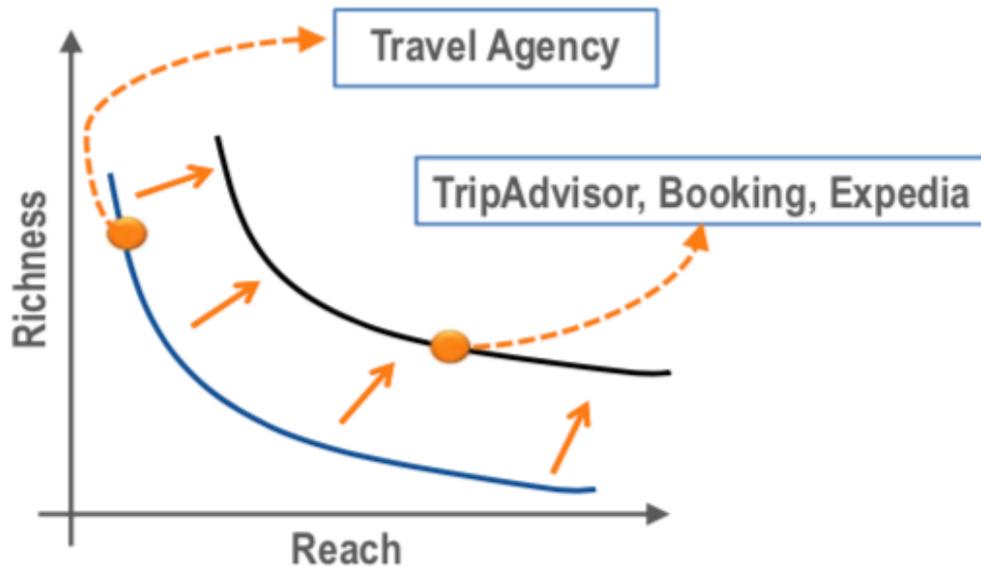


**Figura2.3** Disruptive innovation. Fonte: Christensen Clayton M., Michael Raynor and Rory McDonald (2015). "What Is Disruptive Innovation?"

Nell'ambito del turismo, un esempio recente di *disruptive innovation* si può riscontrare nell'ascesa delle agenzie di viaggio online (*online travel agency*, OTA), come Expedia o Travel velocity, se confrontate con le agenzie di viaggio aventi sede fisica (*Christensen et al.*, 2003).

Le motivazioni del successo delle OTA sono state descritte nel primo capitolo; tuttavia il motivo principale, considerando la teoria della *disruptive innovation*, è la dissociazione tra mondo fisico e mondo informatico, quindi la contrapposizione tra i due modelli economici *bits vs atoms*. I servizi informatici seguono regole economiche differenti rispetto ai beni fisici, specialmente quando il servizio è veicolato tramite internet (vedi Paragrafo 1.2). Per quanto riguarda i contenuti informatici, essi sono caratterizzati da due dimensioni contrapposte (*Evans Philip B. et al.*, 1997; *Evans Philip B. et al.*, 2000; *Duncan Peter et al.*, 2001):

- *Richness* o *ricchezza dell'informazione*, è l'ammontare di informazione che può essere trasmessa. Maggiore sarà la *richness*, maggiore sarà il livello di varietà, di customizzazione e di scambio dell'informazione.
- *Reach* o *ampiezza*, è il numero di possibili consumatori raggiunti dall'informazione.



**Figura 2.4** Trade-off tra richness e reach

In Figura 2.4 possiamo notare la contrapposizione tra *richness* e *reach*, tradizionalmente visti come delle caratteristiche conflittuali: all'aumentare di un parametro diminuisce l'altro. La diffusione di internet ha permesso di traslare la curva iperbolica verso l'alto, così da permettere di ottenere un migliore trade-off per le OTA. Infatti, le OTA, con l'avvento di internet, subiscono il trade-off tra *richness* e *reach* in maniera più mitigata rispetto alle agenzie di viaggio tradizionali.

Un'evidenza empirica della teoria di *Christensen et al.* per la piattaforma Airbnb è riscontrabile nella pubblicazione di *Daniel Guttentag* (2013). L'autore nella ricerca espone tre ragioni per cui Airbnb è una *disruptive innovation*:

- I tempi di crescita della piattaforma rispecchiano i tempi di crescita ipotizzati dalla teoria. Infatti, a partire dal 2008 il mercato di Airbnb è cresciuto lentamente per poi avere una crescita esponenziale dal 2011.
- Si tratta di una soluzione alternativa al tradizionale mercato del turismo, in quanto riesce a pubblicizzare gli annunci attraverso internet, così da attirare i consumatori.
- La pubblicazione dell'annuncio è completamente gratuita e la società gestisce le prenotazioni e le transazioni.

Come sostiene la teoria, un'innovazione, per essere definita "dirompente", può avere delle performance discrete per gli attributi di punta dei competitor, ma deve necessariamente primeggiare in nuove specifiche. Rispetto agli hotel, Airbnb non eccelle in qualità del servizio, sicurezza e reputazione del marchio; d'altra parte, è una soluzione sicuramente più

economica che consente ai consumatori di viaggiare con un budget limitato. Tuttavia, in linea con la teoria di *Christensen et al.*, la piattaforma sta tentando di migliorare la qualità del prodotto offerto, attraverso sia un meccanismo di verifica dell'identità dei soggetti che una assistenza telefonica 24 ore su 24.

#### **2.4 L'impatto economico e sociale di Airbnb**

Airbnb offre sicuramente dei vantaggi ad entrambi i versanti del mercato: gli host possono guadagnare un reddito extra dall'affitto di breve periodo per alloggi inutilizzati, mentre i guest possono viaggiare con un budget ridotto (*Guttentag, 2013*). Tuttavia, la massiccia penetrazione della piattaforma nelle città ad alto tasso turistico ha provocato un acceso dibattito accademico sugli effetti positivi o negativi che ne derivano.

Nel report stilato da Airbnb dal titolo "Fattore sharing: l'impatto economico di Airbnb in Italia", si mettono in luce i benefici economici, ambientali e sociali riscontrati non solo nelle grandi città italiane ma anche nelle zone rurali. In Italia, l'impatto economico complessivo è pari a 3,4 miliardi di euro supportando così 98.400 posti di lavoro, il che significa che a beneficiare, oltre ai guest e agli host, sono anche le imprese locali.

Tuttavia, la penetrazione massiccia di Airbnb nel settore turistico è considerata come una potenziale minaccia per il settore alberghiero, il quale è soggetto a notevoli barriere all'entrata come investimenti iniziali consistenti e normative e/o regolamentazioni stringenti (documentazioni e licenze) (*Aznar et al., 2015*). La struttura dei costi di queste imprese rende la loro redditività vulnerabile a qualsiasi shock negativo della domanda, e per questo motivo, un calo delle entrate di solito implica una maggiore riduzione dei profitti. Aumentando il numero degli annunci, e di conseguenza l'offerta degli alloggi, Airbnb offre un'alternativa più economica alle strutture alberghiere, senza costi fissi (*Aznar et al., 2016*).

L'impatto economico può variare in base a diversi fattori: la localizzazione geografica, la stagionalità e il segmento di mercato alberghiero (*Zervas et al., 2017*). In riferimento a quest'ultimo, dalla letteratura si evince che c'è una concorrenza diretta tra gli alberghi di categoria medio bassa (1-3 stelle) e l'offerta proposta sulla piattaforma Airbnb. Infatti, *Guttentag e Smith (2017)* hanno osservato empiricamente che la maggior parte dei guest, circa i due terzi, hanno scelto una soluzione abitativa paragonabile ad una camera di albergo di fascia medio bassa.

Come è stato già accennato, il settore alberghiero non solo risente della competizione sul prezzo, ma è anche fortemente regolamentato a differenza di Airbnb, che invece può espandere l'offerta ovunque e senza limitazioni dato che sfrutta immobili già esistenti. Di

conseguenza, poiché il gettito delle casse comunali e statali si basa in parte sui ricavi di settori come quello alberghiero, si verificherà un minor introito fiscale con conseguente danneggiamento a breve termine. Per ovviare a tutto ciò sarà necessario introdurre una regolamentazione ad-hoc di Airbnb (*Zervas et al.*, 2017). Naturalmente, risulta difficile misurare l'impatto netto delle piattaforme P2P come detto in precedenza.

Un altro argomento fortemente dibattuto è il fenomeno della *gentrification* (o “gentrificazione”) dettato dal *business model* di Airbnb. Si tratta di un processo di riqualificazione estetica dei quartieri, che implica un aumento dei valori immobiliari, e quindi dei prezzi, favorendo così l’espulsione (diretta o indiretta) degli abitanti meno facoltosi (Wikipedia; *Gainsforth*, 2019). Il primo effetto della “gentrificazione” è il *rent gap* che si instaura nel momento in cui si avrà un aumento del prezzo degli affitti a lungo termine a causa dell’incremento della domanda degli affitti a breve termine (*Wachsmuth et al.*, 2018). Un secondo effetto riguarda le attività economiche locali che devono essere in grado di adeguarsi alle esigenze di una clientela differente; nel caso questo non accada, potrebbero andare incontro alla chiusura dell’attività. A Barcellona, ad esempio, gli affitti di breve periodo sono distribuiti in tutta la città; tuttavia, questi tendono a concentrarsi nel centro della città (anche in quartieri residenziali), ponendo questa area ad una forte pressione turistica (*Gutierrez et al.*, 2017).

Infine, un’altra evidenza che è stata appurata da diverse ricerche scientifiche, riguarda la discriminazione razziale alla quale gli host e i guest sono soggetti (*Cheng et al.*, 2018; *Edelman et al.*, 2017). Questo aspetto è stato affrontato nel paper accademico del 2017 di *Edelman et al.*, in cui gli autori hanno dimostrato come il colore della pelle possa influenzare negativamente la domanda di affitto. Nello specifico, a parità di condizioni, gli host di colore impongono prezzi mediamente inferiori rispetto agli host di etnia caucasica.

## **2.5 Pricing strategy**

Uno dei più grandi dilemmi che ha dovuto affrontare il board di Airbnb è l’introduzione di uno strumento a sostegno degli host per la scelta del prezzo. Infatti, è stato stimato che gli host perdono fino al 46% delle loro entrate a causa di una tariffazione inefficiente (*Hill*, 2015), che ha un effetto negativo anche sugli introiti di Airbnb. A differenza del settore alberghiero, in cui sono presenti professionisti in grado di stimare analiticamente i prezzi delle camere, gli alloggi di Airbnb sono gestiti da soggetti con una limitata conoscenza del settore turistico. Per tale motivo, nel momento in cui bisogna stabilire il prezzo del proprio alloggio, l’host si sente perplesso e confuso (*Hill*, 2015).

Le prime versioni dell'algoritmo di determinazione del prezzo, rilasciato nel 2012, stimavano la tariffa dell'alloggio in relazione alla geo localizzazione di altri annunci: nel dettaglio venivano considerati quelli con proprietà simili, presenti in un determinato raggio (Hill, 2015). Con l'avanzare del tempo, l'algoritmo è stato perfezionato e ha permesso di stabilire il prezzo in base a diversi fattori, quali ad esempio stagionalità, eventi locali, location e servizi aggiuntivi o unici (Hill, 2015). Naturalmente, Airbnb concede agli host la possibilità di sfruttare o meno l'algoritmo.

Nel dettaglio, l'algoritmo si basa su un modello di stima del valore di mercato, definito *prezzo edonico* o *hedonic price*, che si applica perfettamente allo studio di un mercato caratterizzato da un alto grado di personalizzazione, come quello di Airbnb (Gibbs et al., 2018; Gibbs et al., 2018). Il modello applicato è quello di regressione multipla in cui il prezzo osservato di un bene è spiegato dall'insieme delle caratteristiche che lo distinguono. In particolare, i coefficienti stimati spiegano il contributo, positivo o negativo, di ciascuna delle caratteristiche del bene alla definizione del prezzo di mercato. Anche se l'algoritmo serve a limitare una tariffazione inefficiente, comunque la scelta del prezzo da parte degli host di Airbnb è influenzato fortemente da alcuni parametri: la posizione e la dimensione (Gibbs et al., 2018).

Attraverso delle analisi empiriche, Dogru et al. (2017) hanno identificato alcune variabili che condizionano la tariffa degli alloggi da parte degli host:

- I prezzi delle case intere e delle camere private sono rispettivamente del 141% e del 28% superiori a quelli delle camere condivise.
- I prezzi sono più alti del 17% per gli alloggi che richiedono una tassa di pulizia rispetto alle proprietà che non la richiedono.
- I feedback influenzano positivamente, anche se in maniera non significativa, i prezzi delle inserzioni.
- La pubblicazione di foto aggiuntive degli alloggi influisce linearmente sui prezzi, ovvero un aumento dell'1% del numero di foto porta ad un incremento dell'1% del prezzo.
- Gli alloggi offerti alle famiglie hanno tariffe più alte dell'11%.
- Offrendo l'accesso alla lavatrice e all'asciugatrice i prezzi aumentano rispettivamente del 6% e del 10%.
- Servire la colazione gratuita aumenta i prezzi dell'11% rispetto agli alloggi che non la offrono.

- Gli alloggi adatti per eventi hanno tariffe più alte del 6%.
- I prezzi degli alloggi diminuiscono all'aumentare della distanza dal centro città.

## 2.6 Crisi economica e aspetti futuri

“Stiamo vivendo tutti una delle più drammatiche crisi della nostra vita e i suoi sviluppi hanno portato a uno stop dei viaggi internazionali. L'attività di Airbnb ha subito un forte impatto e i ricavi di quest'anno, alle stime attuali, saranno meno della metà di quelli del 2019”

Queste sono le parole pronunciate da Brian Chesky, fondatore e attuale CEO di Airbnb, per commentare la crisi economica causata dalla pandemia COVID-19. Il fatturato della piattaforma ha risentito gravemente della crisi del settore turistico provocata dai continui lock-down attuati dai governi nazionali. Ciò ha determinato un severo piano di taglio del personale che ha previsto il licenziamento di 1900 dipendenti, corrispondente a quasi un quinto del totale. La pubblicazione di *Chen et al. (2020)* mostra evidenze del fatto che la pandemia ha causato una perdita di reddito pari al 70% degli host di Airbnb a Sidney. Difatti, chi ha risentito maggiormente di questa crisi sono gli host, i quali possono essere definiti dipendenti informali della piattaforma. Oltretutto, molti host non sono rientrati nei programmi di sostegno finanziario dei governi, mostrando una evidente vulnerabilità della *sharing economy* durante un periodo di crisi economica.

Nella loro recente pubblicazione, *Dolnicar et al. (2020)* hanno proposto due ipotesi su come questa crisi economica influenzerà il futuro di Airbnb e piattaforme simili, basandosi su due premesse:

- Lo scenario economico causato dalla pandemia COVID-19 può esser definito un super-shock economico, il quale è “un evento inaspettato o imprevedibile che influisce positivamente o negativamente su un'economia. Tecnicamente, si tratta di un cambiamento imprevedibile di fattori esogeni - cioè di fattori inspiegabili per un modello economico - che possono influenzare le variabili economiche endogene.” (Wikipedia).
- I super-shock impattano in maniera differente sulle varie tipologie di host (*capitalist, befrienders e ethicists*).

La prima ipotesi avanzata dai ricercatori è che la percentuale di annunci su Airbnb diminuirà. Lo shock economico indotto dalla pandemia determinerà reazioni differenti da parte degli host: alcuni host professionisti decideranno di rimanere sul mercato a breve

termine in quanto sono neutrali al rischio di fallimento. Al contrario, altri host professionisti opteranno per gli affitti a lungo termine poiché garantirà loro una certa stabilità scegliendo così di abbandonare Airbnb.

La seconda ipotesi suggerita dagli autori è che la domanda dei viaggiatori recupererà, ma non raggiungerà i livelli pre-COVID-19. Una volta eliminate le restrizioni, la richiesta di affitti a breve termine aumenterà nuovamente e sarà rapida. Tuttavia, gli host professionisti analizzeranno i rischi associati a nuovi shock economici e saranno riluttanti a offrire i propri alloggi per brevi periodi. Infatti, si prevede che l'offerta raggiungerà un determinato livello, indipendentemente dalla crescita della domanda.

Il paper di *Dolnicar et al.* ci pone di fronte ad un dilemma. Uno shock esogeno della domanda e dell'offerta, come quello provocato dal COVID-19, potrebbe determinare una riduzione del *rent-gap* (*Wachsmuth et al., 2018*) e la mitigazione del fenomeno della gentrificazione. Il rischio di un nuovo shock sarà valutato economicamente in quanto inciderà sui redditi degli host e sarà una nuova barriera alla crescita delle piattaforme P2P nel settore turistico.

## **2.7 Scopo del lavoro**

Dopo aver trattato in modo approfondito il mercato delle piattaforme e in particolare Airbnb, la seconda parte dell'elaborato ha come scopo l'analisi dei trend delle diverse variabili economiche attraverso un approccio descrittivo e l'applicazione delle metodologie Event Study (ES) per alcuni match del Mondiale di Calcio del 2018 in Russia. Per affrontare tale studio sarà necessario valutare l'impatto economico del Mondiale di Calcio in Russia, specialmente nel settore turistico e definire la domanda di ricerca alla base del nostro studio.

### *2.7.1 Impatto economico del Mondiale di Calcio in Russia*

La Coppa del Mondo è il torneo di calcio più prestigioso al mondo, ed è anche l'evento sportivo più seguito al mondo (Wikipedia). L'ultima edizione dei mondiali di calcio si è disputata in Russia nel 2018 e, nello specifico, in 11 città diverse: Mosca, San Pietroburgo, Kazan, Samara, Sochi, Volgograd, Königsberg, Rostov sul Don, Saransk, Nizhnij Novgorod ed Ekaterinburg.

Secondo un rapporto ufficiale del Ministero delle Comunicazioni della Federazione Russa, per assistere alle partite della Coppa del Mondo FIFA 2018, sono stati rilasciati un totale di 1,83 milioni di "FAN-ID", i cosiddetti "passaporti dei tifosi". Più della metà di

questi sono stati richiesti da cittadini russi (987.000), mentre quelli per i cittadini stranieri ammontavano a circa 843.000.

Considerando i costi dell'organizzazione, gli analisti della società di consulenza McKinsey & Company hanno calcolato che per realizzare questo evento sportivo sono stati spesi ben 1.200 miliardi di rubli, pari a circa 16,02 miliardi di dollari. Di questi, circa 8,52 miliardi di euro sono stati investiti nella costruzione e nella ristrutturazione di stadi e aeroporti, stima di spesa ben più bassa rispetto a quella calcolata dall'agenzia russa Rossbiznes-Konsalting (RBK) (circa 14,2 miliardi di dollari). In particolare, quasi un terzo delle spese è servito per la costruzione degli stadi – 9 dei 11 che ospitarono i gironi e le fasi finali sono stati infatti costruiti apposta per la competizione – mentre il resto è stato destinato all'ottimizzazione delle infrastrutture e trasporti ed alle strutture ricettive come hotel, alberghi e B&B. Circa l'84% delle spese è stato coperto dal governo centrale o regionale, mentre il restante 26% è stato sostenuto da compagnie private o a partecipazione statale.

Le entrate sono molto più complesse da quantificare. Secondo quanto affermato durante una conferenza stampa sull'impatto del Mondiale di Calcio sul turismo in Russia da Maya Lomidze, direttore esecutivo dell'Associazione dei Tour Operator della Russia (ATOR), si parla di oltre 5 miliardi di dollari.

### *2.7.2 Domanda di ricerca*

Il quesito a cui l'elaborato tenterà di rispondere è: “Come uno specifico Mega-Evento, ad esempio il Mondiale di Calcio, influenza le variabili economiche nel breve periodo?”. Maurice Roche (2003) afferma che i Mega-Eventi sono meglio intesi come "eventi culturali su larga scala (compresi quelli commerciali e sportivi), che hanno un carattere drammatico, un richiamo popolare di massa e un significato internazionale". L'autore della ricerca suggerisce due caratteristiche principali che contraddistinguono i Mega-Events:

- Conseguenze sociali significative per la città, regione, nazione in cui vengono ospitati
- Copertura mediatica internazionale

Una ulteriore definizione dei Mega Events è stata data da Kenneth Roberts (2004) il quale definisce "Mega" gli eventi sportivi che sono "discontinui", fuori dal comune e in grado di trasmettere messaggi promozionali a miliardi di persone attraverso la televisione e altri mezzi di comunicazione.

In particolar modo, gli eventi sportivi sono classificati come Mega-Eventi in quanto l'elevata esposizione mediatica determina uno shock sociale ed economico difficile da quantificare. Oltretutto, anche i piccoli incontri sportivi a livello locale attirano grandi masse di persone che condividono la stessa passione, i mass-media e i molteplici stakeholders appartenenti a settori economici e sociali.

L'analisi condotta da Lee et al. (2005) ci consente di studiare l'impatto sociale ed economico dei Mondiali di calcio del 2002 in Corea del Sud. La ricerca condotta dagli autori ha evidenziato come l'evento sportivo abbia direttamente e indirettamente attirato il 57,7% dei turisti in più durante il periodo dell'evento, aumentando così l'attrattiva del paese. L'impatto economico superò ogni aspettativa: 1,35 miliardi di dollari di produzione (vendite), 307 milioni di dollari di entrate e 713 milioni di dollari di valore aggiunto per la Corea del Sud.

Nel paper *“Mega-Events: The effect of the world’s biggest sporting events on local, regional, and national economies”*, l'autore ha stilato una tabella dove sono elencati alcuni Mega-Eventi sportivi organizzati tra il 1994 e il 2010 e le rispettive stime economiche rilasciate dagli organizzatori di questi eventi (Tabella 1).

Event	Year	Sport	Impact	Author
Super Bowl (Atlanta)	1994	Football	\$166 million 2,736 jobs	Jeffery Humphreys, Georgia State University <sup>1</sup>
Super Bowl (Miami)	1999	Football	\$393 million	Kathleen Davis, Sports Management Research Institute <sup>2</sup>
Super Bowl (San Diego)	2003	Football	\$367 million	Marketing Information Masters, Inc. <sup>3</sup>
MLB All-Star Game	1999	Baseball	\$75 million	Bud Selig, MLB <sup>4</sup>
MLB World Series	2000	Baseball	\$250 million	Comptroller of New York City <sup>5</sup>
NCAA Men's Final Four (St. Louis)	2001	Basketball	\$110 million	St. Louis Convention and Visitor's Bureau <sup>6</sup>
U.S. Open	2001	Tennis	\$420 million	Sports Management Research Institute <sup>7</sup>
World Cup	2006/ 2010	Soccer	\$6 billion 129,000 jobs	South Africa Football Association <sup>10</sup>
Summer Olympics (Atlanta)	1996	Multiple	\$5.1 billion 77,000 jobs	Jeffery Humphreys and M. K. Plummer <sup>11</sup>
Winter Olympics (Vancouver, British Columbia)	2010	Multiple	\$10.7 C billion 244,000 jobs	B.C. Ministry of Competition, Science and Enterprise and InterVISTAS Consulting <sup>12</sup>

**Tabella 1** Impatto economico dei Mega Events. Fonte: Matheson V.A. (2006). *“Mega-Events: The effect of the world's biggest sporting events on local, regional, and national economies”*

Tuttavia, il ricercatore muove una critica sulle stime fornite: come è stato dimostrato da una parte della letteratura, l'impatto economico degli eventi è limitato e circoscritto, in particolar modo nel caso delle costruzioni di nuove infrastrutture. Matheson precisa che

“l’impatto lordo di questi eventi è sicuramente elevato, attirando migliaia di spettatori e milioni di pubblico televisivo, eppure l’impatto netto dei Mega-Eventi su variabili economiche reali come le vendite tassabili, l’occupazione, il reddito personale e il reddito personale pro capite nelle città ospitanti è trascurabile”.

L’Event Study rappresenta una metodologia di analisi statistica, applicata nel settore finanziario, idonea al nostro caso poiché permette di valutare il comportamento delle variabili economiche nel breve arco temporale comprendente l’evento in questione.

L’obiettivo dell’elaborato sarà quello di adattare al settore turistico, in particolare al segmento di mercato della *sharing economy*, i modelli impiegati nel campo finanziario. Infatti, saranno presentati diversi modelli di riferimento e diverse tecniche econometriche presenti nella letteratura sulla materia e utilizzate per l’analisi inferenziale.

Dopo la stima dei ritorni mediante tale approccio, sarà svolta un’analisi di quelli direttamente imputabili all’evento considerato e che non rientrano nel normale andamento del titolo (Abnormal Returns). Su questi rendimenti anomali verranno poi condotti test statistici per la verifica della loro significatività.

## Capitolo 3

### DATI E METODOLOGIA DI STUDIO

#### 3.1 Descrizione dei dati - AirDNA dataset

Per sviluppare il lavoro di tesi ci si è avvalsi del database inerente alla piattaforma Airbnb fornito da AirDNA, che è una data company di analisi statistiche. Essa utilizza il metodo “web-scraping” per estrarre, attraverso diversi software, i dati dai siti web (ad esempio Airbnb, HomeAway e Vacation Rental By Owner) e raccoglierli in dataset (Wikipedia). I dati vengono visualizzati mediante una matrice in cui ogni colonna della tabella rappresenta una particolare variabile, e ogni riga corrisponde ad un determinato membro del dataset in questione.

Ad oggi, il database di AirDNA comprende 40 paesi (Tabella 1) e copre un arco temporale differente a seconda dei dati che la piattaforma riesce ad ottenere.

Country			
Russia	Greece	Bulgaria	Albania
Germany	Czech Republic	Denmark	Latvia
United Kingdom	Portugal	Slovakia	Macedonia
France	Belgium	Finland	Slovenia
Italy	Hungary	Norway	Kosovo
Ukraine	Sweden	Ireland	Estonia
Spain	Belarus	Croatia	Montenegro
Poland	Austria	Bosnia-Herzegovina	Luxembourg
Romania	Switzerland	Moldova	Malta
Netherlands	Serbia	Lithuania	Iceland

**Tabella 2** Nazioni - AirDNA

Per poter eseguire indagini quantitative e qualitative, AirDNA processa e organizza i dati in tre dataset caratterizzati da un numero differente di campi che danno informazioni sulla singola proprietà. Nello specifico si distinguono:

- Daily Dataset. Questo dataset ha una dimensione di circa 300Gb, ha un numero di campi limitato ed è caratterizzato da informazioni giornaliere su ogni singolo annuncio (Allegato 1).
- Monthly Dataset. La sua dimensione è di circa 40Gb ed è il risultato dell’aggregazione mensile delle informazioni giornaliere di ogni Property ID (Allegato 2).

- Annual Properties Performance Dataset. Tale tipologia di dataset (dimensione di circa 5Gb) raggruppa annualmente i dati mensili per ogni annuncio ed è caratterizzato da una moltitudine di campi e informazioni dettagliate (Allegato 3).

Nel nostro caso, sono stati considerati il Monthly Dataset per lo studio descrittivo delle performance economiche di Airbnb e il Daily Dataset per l'applicazione della metodologia Event Study.

Le dimensioni di questi dataset non consentono di trattare tramite il software Excel le informazioni in esso contenute, in quanto viene superato il limite massimo di 1.048.576 righe. Per tale motivo le operazioni di estrazione e manipolazione dei dati, inerenti alle città in esame, sono state eseguite mediante la libreria software *Pandas* che si basa sul linguaggio di programmazione *Python*. I codici di estrazione e pulizia dati dei due dataset sono disponibili negli Allegati 6.4.1 e 6.4.2.

Per la visualizzazione dei dati, attraverso la creazione di grafici, sono state impiegate le librerie software *Mathplotlib* e *Seaborn* mentre *Scipy.stats* e *Sklearn* sono state utilizzate per l'analisi statistica dei dati.

## 3.2 Metodologia di studio

### 3.2.1 Analisi descrittiva

Prima di procedere all'analisi di tipo descrittivo, necessaria per poter valutare tutte le variabili di indagine della piattaforma Airbnb in Russia e nelle sei città interessate dall'evento calcistico, inizialmente è stata eseguita l'estrazione dei dati e dei campi specifici dal Monthly Dataset, con lo scopo di creare dei dataset specifici per ogni località (Russia, Mosca, San Pietroburgo, Nizhnij Novgorod, Kazan, Samara e Sochi). Successivamente, i campi estrapolati sono stati aggregati in base al mese di riferimento in un arco temporale di tre anni, nello specifico dal 2017 al 2019 (Allegati 7, 8, 9, 10, 11, 12, 13).

Si è poi proceduto all'introduzione di nuovi indici di misurazione come:

- Occupation Rate, che indica il tasso di occupazione dell'alloggio. È stato calcolato attraverso la seguente formula:

$$Occupation Rate = \frac{Reserved Days}{Reserved Days + Availble Days}$$

- Average Monthly Revenue, che rappresenta il ricavo medio dell'alloggio per i giorni prenotati ed è stato calcolato attraverso la seguente formula:

$$\text{Average Monthly Revenue} = \frac{\text{Revenues}}{\text{Reserved Days}}$$

In allegato 6.4.3 è disponibile il codice che ha permesso di effettuare le analisi sui dataset specifici per ogni località.

### 3.2.2 Event Study

Dopo aver esaminato le performance di Airbnb nel mercato russo, si è proceduto all'applicazione della metodologia Event Study (*Fama et al. 1969; Ball et al. 1968*), al fine di comprendere l'impatto economico dei singoli match.

Attualmente l'ES rappresenta uno strumento di analisi statistica fortemente diffuso e utilizzato nel campo economico e in particolare nel settore finanziario. La totalità dei titoli quotati sui mercati finanziari sono affetti da una grande volatilità, la quale può scaturire dall'andamento generale del mercato oppure derivare da fattori particolari in grado di influenzare il prezzo del singolo titolo. Lo scopo dell'ES è di stimare l'effetto di un evento sul valore dell'impresa, attraverso lo studio dei rendimenti anomali del titolo azionario associati all'evento stesso.

La teoria alla base della tecnica ES è l'ipotesi di mercato efficiente, secondo la quale il prezzo di un titolo negoziato sia uguale al valore attuale dei flussi di cassa attesi della società.

In base alla finestra temporale in cui viene analizzato l'impatto dell'evento, è possibile classificare l'ES come segue:

- Metodi di Short - Horizon Event Study (SHES), caratterizzati da un numero limitato di giorni. Studi basati su brevi lassi temporali (1 - 11 giorni simmetrici rispetto l'Event Day) rappresentano la soluzione maggiormente utilizzata in letteratura (*Holler, 2014*).
- Metodi di Long - Horizon Event Study (LHES), la cui valutazione avviene su base annuale.

Prima di svolgere l'analisi, è stato indispensabile compilare dei codici per l'estrazione dei dati e dei campi specifici dal Daily Dataset, con lo scopo di creare dataset per ciascuna località (Russia, Mosca, San Pietroburgo, Nizhnij Novgorod, Kazan, Samara e Sochi). Una volta estrapolati i campi, questi sono stati aggregati in base al giorno di riferimento, in un arco temporale di due anni (dal 2017 al 2018). Inoltre, si è deciso di esaminare la variabile Average Daily Revenue (ADR) o Ricavo Medio Giornaliero:

$$\text{Average Daily Revenue} = \frac{\text{Revenues}}{\text{Reserved Days}}$$

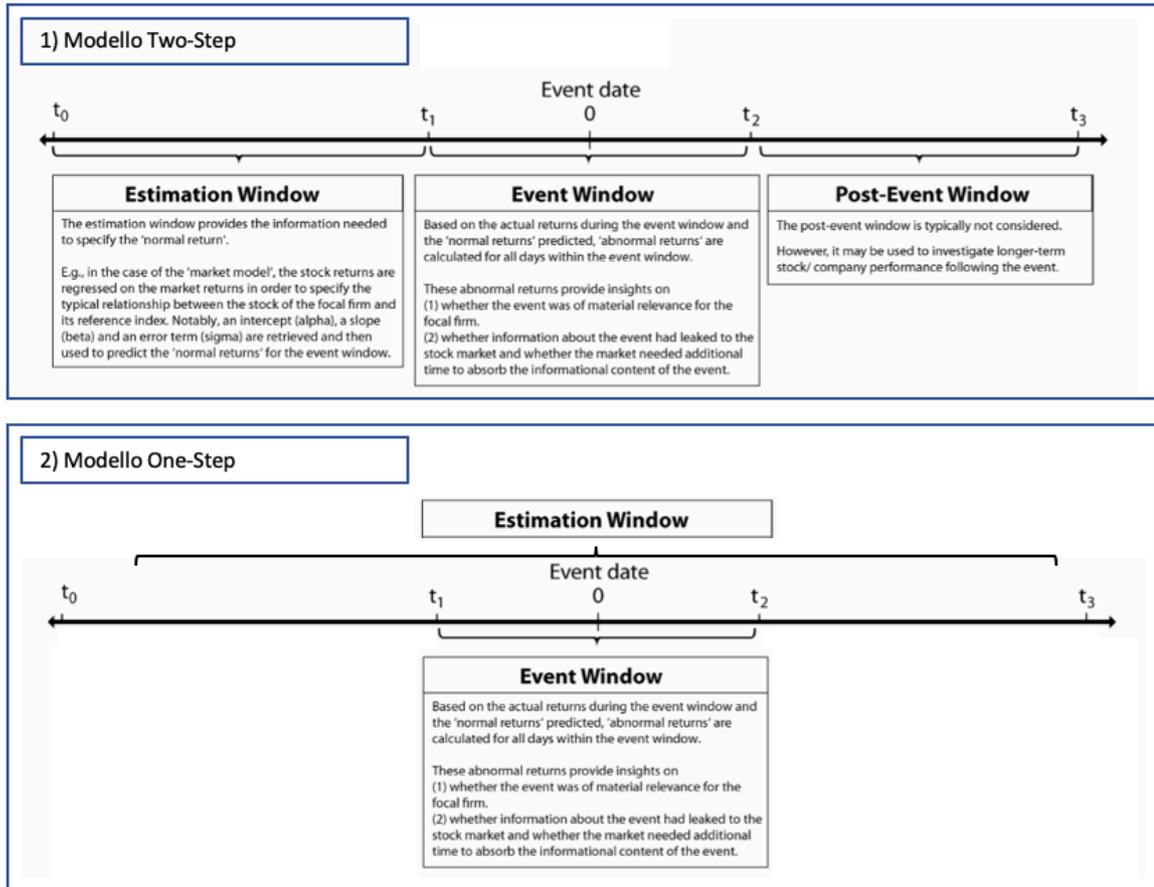
Il modello Event Study applicato è schematizzabile in 6 fasi principali:

- La prima fase per la conduzione di un ES riguarda la scelta di uno o più eventi di interesse e la finestra temporale nella quale valutarne gli effetti (Event Window). Nel nostro caso gli eventi analizzati sono gare calcistiche ed è stata applicata la metodologia SHES in un settore completamente differente da quelli generalmente riscontrati in letteratura, ovvero il settore del turismo. Il conseguirsi degli eventi sportivi disputati nella stessa città a distanza di qualche giorno potrebbe risultare problematica per la scelta della finestra temporale. Per tale motivo è stato stilato un calendario del Mondiale di Calcio inerente agli ultimi eventi calcistici disputati nelle città russe (Tabella 3). È stato così scelto un Event Window della durata di 13 giorni, e in particolare un arco temporale di intervallo [-3; +8] comprendente l'Event Day, ovvero il giorno dell'evento stesso, indicato come il giorno 0.

Incontro Sportivo	Data e ora	Luogo
Uruguay – Francia	6 luglio 2018 alle ore 17:00	Nizhnij Novgorod
Brasile – Belgio	6 luglio 2018 alle ore 21:00	Kazan
Svezia – Inghilterra	7 luglio 2018 alle ore 18:00	Samara
Russia – Croazia	7 luglio 2018 alle ore 21:00	Sochi
Belgio – Inghilterra	14 luglio 2018 alle ore 17:00	San Pietroburgo
Francia – Croazia	15 luglio 2018 alle ore 18:00	Mosca

**Tabella 3** Eventi sportivi scelti

- Si procede specificando un ulteriore periodo temporale, l'Estimation Window, in cui si stimano gli ADR normali. Nella maggior parte dei modelli l'Estimation Window precede l'Event Window; in altri casi invece, quest'ultimo è incluso all'interno della Estimation Window (Figura 3.1). La scelta della durata temporale dell'Estimation Window dipenderà dal modello benchmark di riferimento.
- Successivamente si definisce la metodologia da applicare per individuare gli ADR normali di una determinata città. È possibile far riferimento a due approcci differenti: Statistical Models (come il Costant-Mean-Return, il Market Model, etc.) ed Economic Models (come il Capital Asset Pricing Model (CAPM), etc.). Per poter applicare i modelli fino ad ora menzionati, è necessario che l'evento sia esogeno, ovvero è l'evento stesso a determinare una variazione dell'ADR e non altri fattori. Nel caso in esame, sono stati applicati i modelli statistici dato che i modelli economici sono caratterizzati da una serie di specifiche variabili non rilevabili nel settore turistico.



**Figura 3.1** Caratteristiche delle differenti metodologie.

- Si calcolano gli *Abnormal Returns* (AR) nell'Event Window come differenza tra gli ADR effettivi della città e gli ADR normali stimati. In sostanza, gli AR quantificano l'impatto che l'evento ha causato sul ADR, ovverosia quanto l'ADR di una città sia scostato dal suo valore atteso:

$$\widehat{AR}_{it} = ADR_{it} - \widehat{ADR}_{it} = ADR_{it} - E[R_{it}|X_t]$$

- Dagli AR ottenuti nella fase precedente si calcolano i CAR (Cumulative Abnormal Returns). Per completezza vengono definite alcune variabili come AAR (Average Abnormal Returns) e CAAR (Cumulative Average Abnormal Returns) anche se nel nostro studio non verrà svolta un'analisi in cross-section.

$$CAR_t = \sum_{t=1}^T AR_t$$

$$AAR_t = \frac{1}{N} \sum_{t=1}^T AR_t$$

$$CAAR_t = \sum_{t=1}^T AAR_t$$

- L'ultima fase prevede la verifica della significatività statistica delle ultime variabili citate, attraverso test statistici, al fine di comprendere se lo scostamento tra il rendimento effettivo e quello atteso sia dovuta al caso o abbia un significato economico. Quindi è stato condotto un particolare test statistico (T-Test) e nella formula del T-Test è stata considerata la deviazione standard del campione degli AR.

$$t_{ARt} = \frac{AR_{it}}{S_{ARi}}$$

## Capitolo 4

### ANALISI DESCRITTIVA

In questo capitolo, l'attenzione si è focalizzata sulle performance e sull'andamento generale della piattaforma Airbnb nel mercato russo, per poi esaminare in modo approfondito le città selezionate. Per avere una visione di insieme, come già accennato nel capitolo precedente, è stato considerato l'arco temporale compreso tra il 2017 e il 2019. In una prospettiva descrittiva, l'analisi dei dati sarà essenziale per illustrare alcuni fenomeni economici e per individuare eventuali relazioni tra le variabili.

Prima di procedere, è necessario descrivere brevemente il settore turistico russo. La Federazione Russa è uno stato transcontinentale che si estende per un quarto in Europa e per tutto il resto in Asia ed è il più vasto stato del mondo (Wikipedia). Nei primi anni del ventunesimo secolo, il tasso di crescita del Prodotto Interno Lordo è stato tra i più elevati a livello globale, così da essere considerata una tra le più grandi potenze mondiali. Tuttavia, la crisi finanziaria del 2006 ha destabilizzato lo scenario economico russo riponendo dubbi sulla stabilità del sistema economico.

Totale visitatori		%
2019	32.866.265	↑ 0,970%
2018	32.550.677	↑ 1,608%
2017	32.035.443	↑ 1,808%
2016	31.466.538	↓ -6,708%
2015	33.729.187	↑ 4,033%
2014	32.421.490	↑ 5,292%
2013	30.792.091	↑ 9,283%
2012	28.176.502	↑ 13,013%
2011	24.932.061	↑ 11,897%
2010	22.281.217	↑ 4,417%
2009	21.338.650	↓ -9,873%
2008	23.676.140	↑ 3,350%
2007	22.908.625	0

**Tabella 4** Numero di visitatori stranieri per anno in Russia. Fonte: Wikipedia

Nonostante sia necessario possedere il visto turistico per poter accedere nella nazione, la Russia ha visto una rapida crescita del turismo grazie all'immenso patrimonio culturale e ai paesaggi naturali eterogenei (Wikipedia). Nella Tabella 4 è visibile il trend di crescita per anno relativo al numero di visitatori stranieri.

Impatto economico del Turismo (Mld \$)			
2019	70,758	↑	0,90%
2018	70,128	↑	1,01%
2017	69,424	↑	0,11%
2016	69,347	↑	10,33%
2015	62,853	↓	-2,99%
2014	64,790	↓	-2,44%
2013	66,408	↑	1,22%
2012	65,606		0

**Tabella 5** Impatto economico del settore turistico per anno in Russia. Fonte: World Tourism Organization.

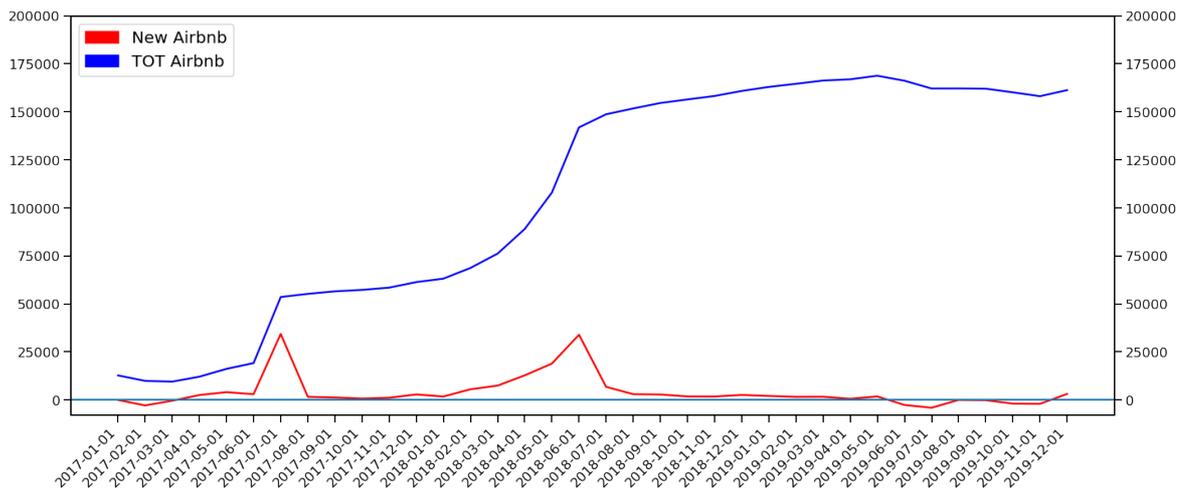
Anche l’impatto economico del settore turistico segue l’andamento del numero di turisti stranieri, come si può notare dalla tabella 5.

L’introito economico generato dal turismo ha contribuito alla crescita economica dell’intero paese, incrementando il numero dei posti di lavoro, il Prodotto Interno Lordo e il Reddito Pro-Capite.

#### 4.1 Airbnb in Russia

In Russia, la crescita del settore turistico negli ultimi anni ha contribuito anche allo sviluppo della piattaforma Airbnb. Mentre in Europa le prime proprietà sulla piattaforma si iniziano a diffondere dal 2008, la Russia si presenta ancora come un mercato acerbo e non allettante per gli host. Una situazione ben diversa si può riscontrare dal 2017 in poi: come si può osservare dalla Figura 4.1, una serie di Mega-Eventi (la Confederations Cup a fine Giugno del 2017 e i Mondiali di Calcio disputati tra Giugno e Luglio 2018) ha scaturito un crescente interesse da parte dei proprietari di case ad affittare i propri alloggi per brevi periodi. Il numero degli annunci è passato da 12.775 nel 2017 a 161.277 nel 2018, con un incremento percentuale del 1162%. In particolare, nel mese di Luglio 2017 si è registrato un saldo netto di nuove proprietà di 34.374, seguito dal mese di Giugno 2018 con 33.945. Tuttavia, la fine di questi Mega-Eventi ha causato una contrazione del numero di nuovi annunci pubblicati su Airbnb.

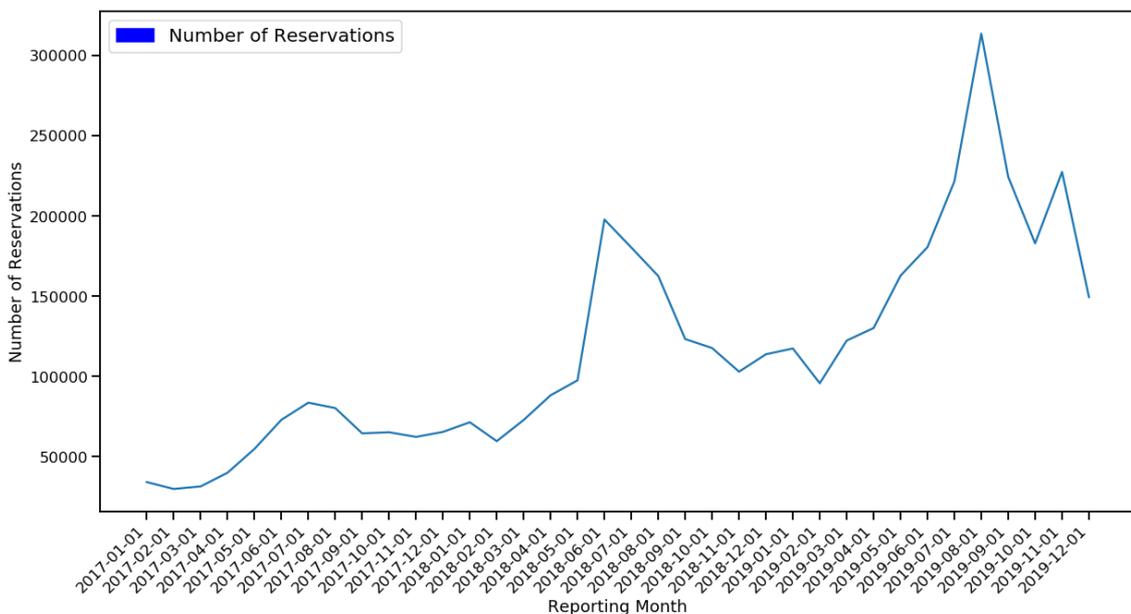
In allegato 6.6.1 sono reperibili tutti i dati e le variabili economiche inerenti alla piattaforma Airbnb in Russia.



**Figura 4.1** Crescita di Airbnb in Russia

In Figura 4.2 viene mostrato l'andamento del numero di prenotazioni effettuate sulla piattaforma, che dipende sia dai Mega-Eventi che dalla stagionalità, ed è stata osservata una maggiore frequenza nei mesi estivi. A differenza delle evidenze riscontrate per i nuovi annunci, il picco si rileva ad Agosto 2019 con 313.420 reservation.

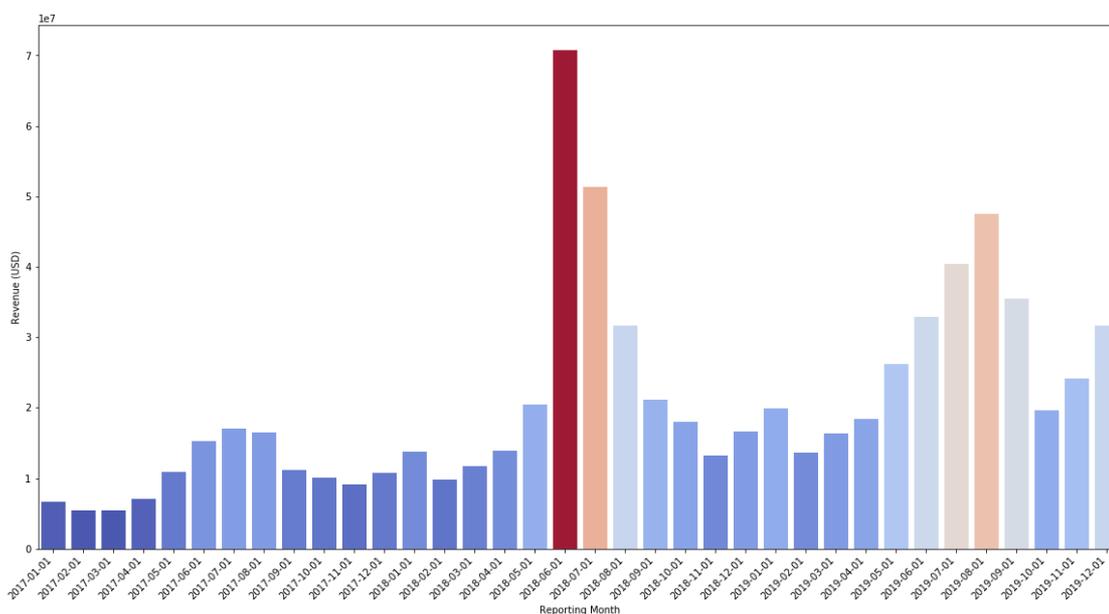
Ciò è dovuto non solo alle motivazioni poc'anzi citate, ma probabilmente anche a un incremento del numero di viaggiatori che hanno scelto il paese come meta turistica. Infatti, nel 2019 è stata registrato una variazione percentuale positiva del numero di prenotazioni di circa il 53,32%.



**Figura 4.2** Trend del numero di prenotazioni in Russia

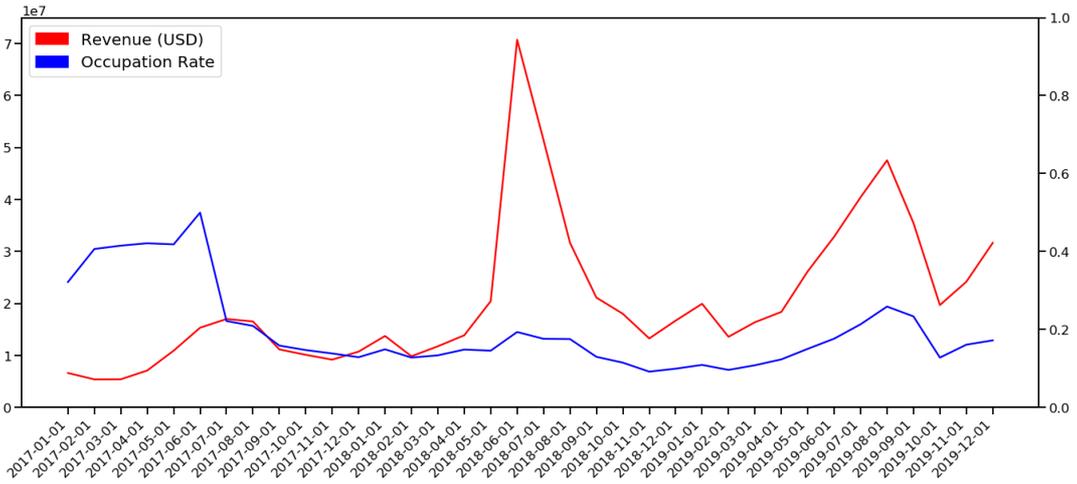
Per quanto riguarda i ricavi generati, l'andamento è pressoché sovrapponibile a quello del numero di reservation in quanto anch'esso sembra risentire dei fenomeni di stagionalità e dei Mega-Eventi (Figura 4.3). L'evidenza di tali supposizioni è stata riscontrata principalmente

nel periodo in cui è stato disputato il Mondiale di Calcio, ovvero a Giugno e a Luglio 2018. In quei mesi, la piattaforma ha generato ricavi complessivi per 122.155.443\$, corrispondenti al 41,76% dei ricavi registrati per tutto l'anno 2018. Eppure, gli introiti del 2019, così come il numero di prenotazioni, sono aumentati del 11,55%, confermando l'andamento di crescita di Airbnb.



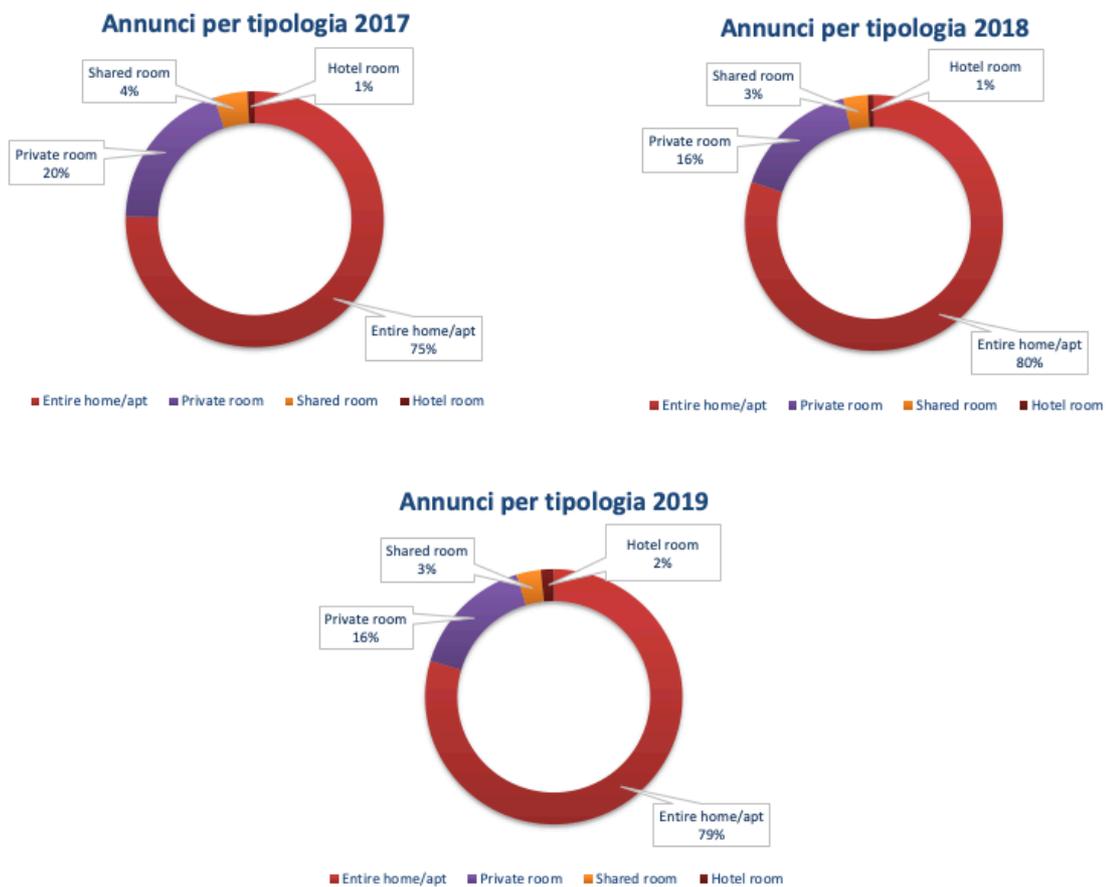
**Figura 4.3** Andamento dei ricavi in Russia

La comparazione tra l'andamento del tasso di occupazione e il trend dei ricavi ha permesso di evidenziare un aspetto interessante. Nella Figura 4.4, si può notare come l'Occupation Rate sia alquanto costante, attestandosi in un intervallo compreso tra 0,10 e 0,20. Per tale motivo, si può affermare che il picco dei ricavi generati durante il Mondiale sia dovuto principalmente all'incremento del prezzo proposto dagli host, e non ad un aumento consistente dell'Occupation Rate. Tuttavia, non è possibile stabilire se la determinazione della tariffa sia dipesa da scelte personali dell'host oppure influenzata dall'algorithm di Airbnb.



**Figura 4.4** Ricavi versus Occupation Rate in Russia

Infine, andando a valutare la tipologia degli annunci pubblicati sul sito della piattaforma (Figura 4.5), si è riscontrato come, nella maggioranza dei casi, gli host offrano interi appartamenti a discapito di altre soluzioni (camere private e/o condivise). Sebbene la popolarità di Airbnb, così come i relativi benefici, sia evidente al punto tale da aver spinto negli ultimi anni anche i proprietari di hotel ad usufruire della piattaforma stessa, la percentuale di adesione risulta essere comunque modesta (circa 1-2%).

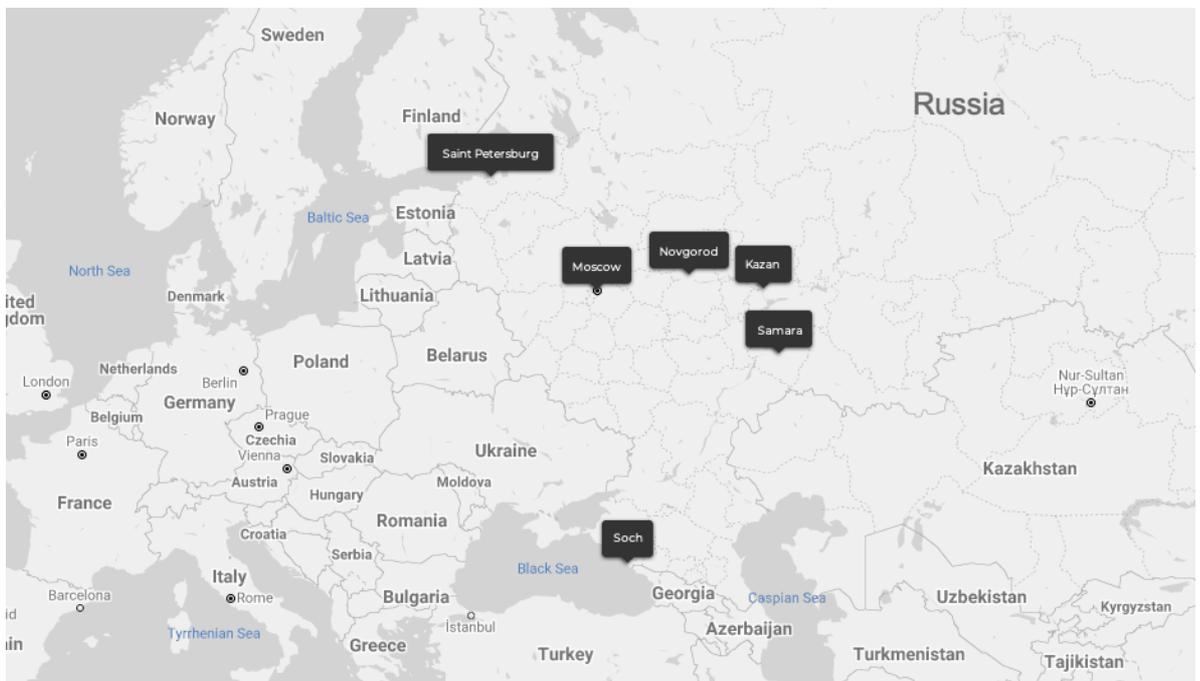


**Figura 4.5** Annunci per tipologia per anno

Quindi, da una prima analisi descrittiva si può concludere che l'evento calcistico considerato abbia favorito in modo evidente lo sviluppo e la diffusione del portale di Airbnb nello stato russo, influenzando positivamente tutte le variabili (economiche e non) esaminate, in particolare i ricavi e il numero di nuove proprietà.

#### 4.2 Confronto tra le singole città

L'indagine descrittiva sviluppata nel precedente paragrafo ha consentito di ottenere una panoramica generale nel mercato russo delle performance di Airbnb in un arco temporale di tre anni. Un'analisi simile, sebbene più approfondita, è stata svolta su alcune città per stabilire eventuali differenze tra di esse. Come è stato già riportato nel terzo capitolo, è stato selezionato un campione di sei città, includente Mosca, San Pietroburgo, Nizhnij Novgorod, Kazan, Samara e Sochi (Figura 4.6).

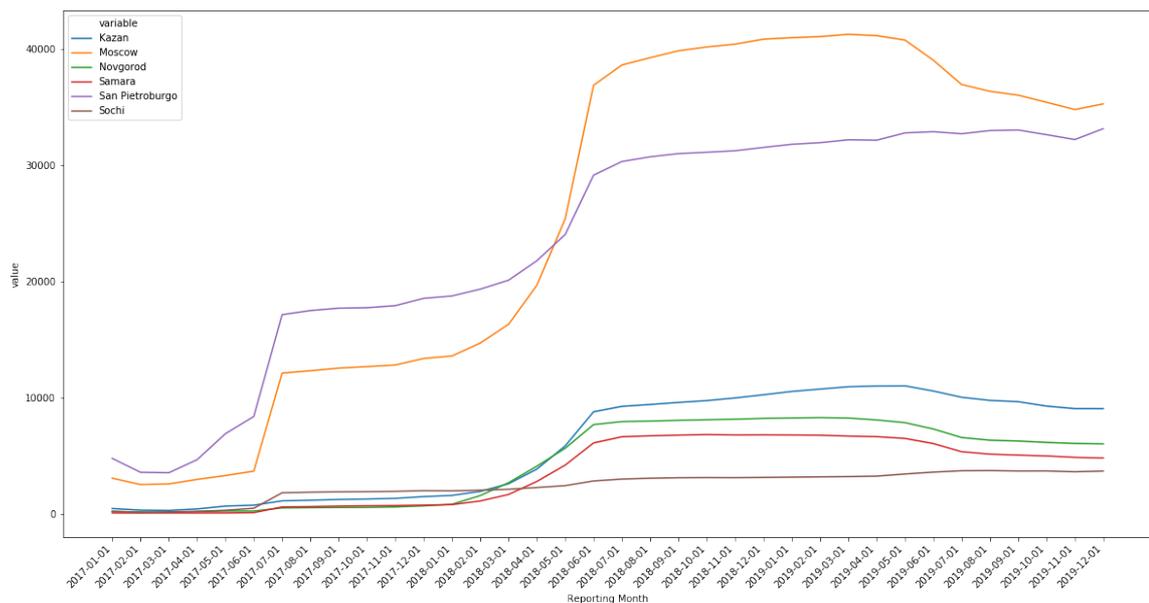


**Figura 4.6** Mappa delle città russe

Per facilitare l'analisi, si è proceduto a suddividere le città in base al numero di abitanti:

- “Metropoli” (Mosca e San Pietroburgo)
- “Periferiche” (Kazan, Novgorod, Samara e Sochi)

Confrontando il numero di proprietà presenti sulla piattaforma nelle sei città si può sin da subito notare una discrepanza tra le metropoli e le città periferiche (Figura 4.7).



**Figura 4.7** Andamento delle singole proprietà presenti sulla piattaforma nelle sei città in esame

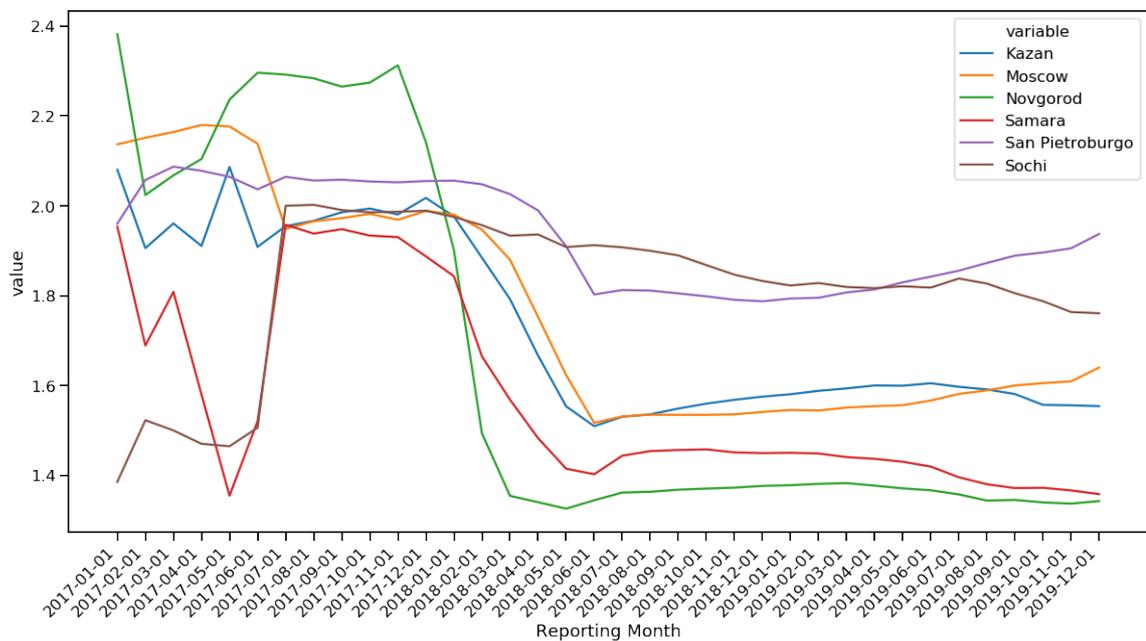
A differenza delle città periferiche, le due metropoli godono di un patrimonio storico e culturale ineguagliabile, rendendole così delle mete turistiche molto ambite. Tuttavia, come si evince dalla Figura 4.7, il tasso di crescita di tutte le città esaminate è alquanto simile. La maggiore variazione percentuale si è registrata nel primo semestre del 2018 nelle città meno conosciute (Samara, Novgorod e Kazan) con rispettivamente 6320%, 3233% e 1544% di nuovi annunci. È importante sottolineare che la Confederation Cup (competizione calcistica premondiale organizzata dalla FIFA disputata nel 2017 a Mosca, San Pietroburgo e Sochi) e il Mondiale di Calcio abbiano accelerato esponenzialmente la diffusione di Airbnb nei mesi antecedenti lo svolgimento di tali eventi.

Nonostante il trend in crescita osservato per il 2018, il saldo complessivo tra proprietà entranti e uscenti dalla piattaforma è risultato negativo nell'anno successivo in quasi tutte le città, ad esclusione di San Pietroburgo e Sochi, nelle quali si è riscontrato un incremento del 4,2% e del 16,51% rispettivamente.

Inoltre, è stata stimata anche la media di alloggi appartenenti al singolo proprietario, mediante il rapporto tra il numero di quest'ultimi e il numero di annunci (proprietà). Per tutte le città considerate, tale indice è risultato maggiore di 1, dimostrando la presenza di multiproprietari sulla piattaforma Airbnb. Vengono definiti nel presente lavoro con il termine "multiproprietari" coloro che possiedono più di un singolo alloggio, indipendentemente dalla tipologia dello stesso o dalla diversa localizzazione geografica. Tra questi è possibile distinguere le agenzie professionali che operano per conto di terzi dai

proprietari che possiedono realmente un numero elevato di appartamenti, gestendoli in maniera autonoma.

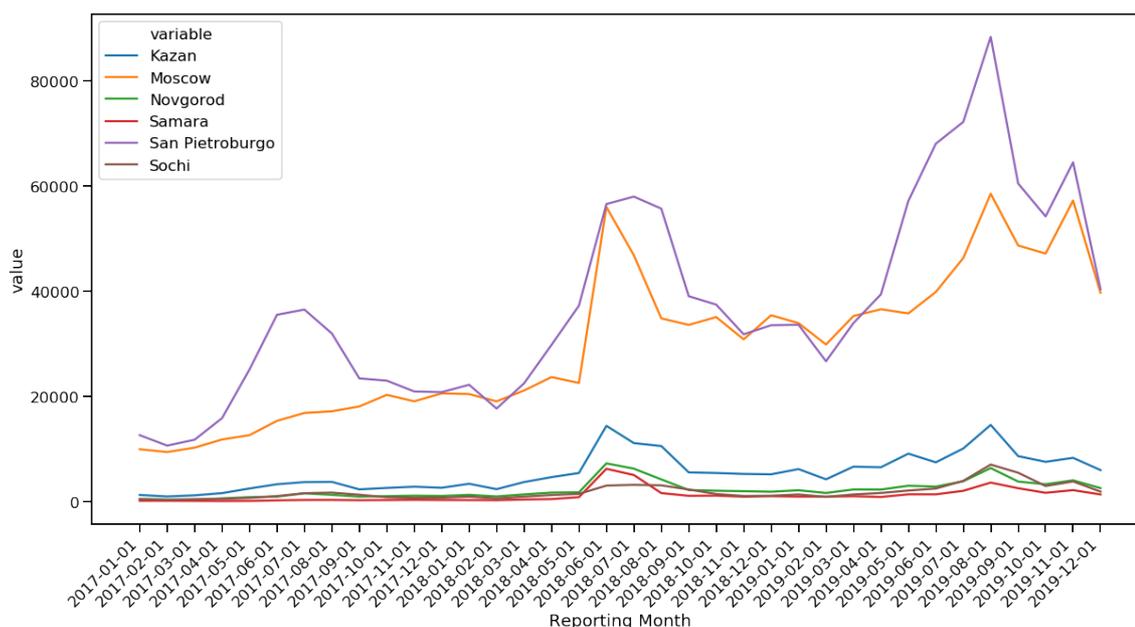
Interessante notare come, con l'affermarsi di Airbnb nella *sharing economy*, imprenditori e non abbiano riconosciuto la piattaforma come un mezzo differente per ottenere maggiori introiti. Airbnb è di fatto una valida alternativa agli affitti a lungo termine nel mercato immobiliare, per soggetti aventi a disposizione alloggi sfitti o capitale da investire. Negli ultimi anni, anche le agenzie professionali di affitti/vendita tradizionali hanno carpito il potenziale insito in queste nuove forme di business, adattandosi alle richieste del mercato, trattando sistemazioni a breve termine.



**Figura 4.8** Andamento della media di alloggi appartenenti al singolo proprietario nelle sei città in esame

Una delle problematiche riscontrate frequentemente nel settore turistico, e di conseguenza anche in Airbnb, è la stagionalità: la quasi totalità delle mete turistiche vedono una maggiore affluenza di visitatori in specifici periodi dell'anno, solitamente nei mesi estivi. Ciò comporta una variazione ciclica prevedibile della serie temporale.

Per avvalorare la tesi della stagionalità, è stato considerato il numero di prenotazioni effettuate dai guest nel corso degli anni, dimostrando che tale misura indica la domanda soddisfatta da parte degli host. Osservando il grafico in Figura 4.9 si evince che le città russe, indipendentemente dalla presenza dei Mega-Eventi o da altri fattori, hanno subito limitatamente o complessivamente il fenomeno di stagionalità.



**Figura 4.9** Andamento del numero di prenotazioni mensili nelle sei città in esame

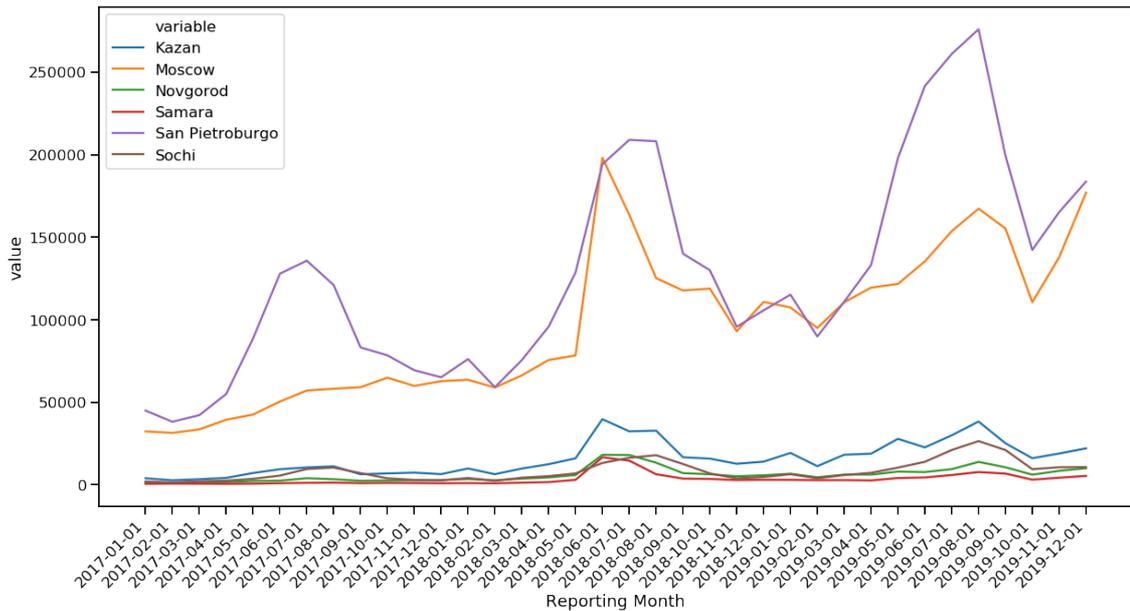
In base alla volatilità della domanda, questa analisi prescinde dalla suddivisione delle città per numero di abitanti. La metropoli di San Pietroburgo risente fortemente del fenomeno della stagionalità con un maggiore numero di prenotazione durante i mesi estivi e una successiva decrescita nei restanti mesi. Ciò accade anche per Sochi, ma in misura più limitata. Invece, le altre città “periferiche” e la città di Mosca sono meno soggette alla stagionalità ma più sensibili dalla presenza di singoli eventi, come il Mondiale di Calcio che si è disputato nei mesi estivi del 2018.

Anche in tal caso, come è stato visto in precedenza per le nuove proprietà, si ravvede un trend di crescita annuale positivo per tutte le città, indice di una maggiore attrattività di quest’ultime dal punto di vista turistico.

	Kazan	Moscow	Novgorod	Samara	San Pietroburgo	Sochi
2018%	165,6%	108,8%	198,5%	508,0%	64,5%	91,9%
2019%	23,5%	34,0%	15,6%	3,1%	44,7%	69,5%

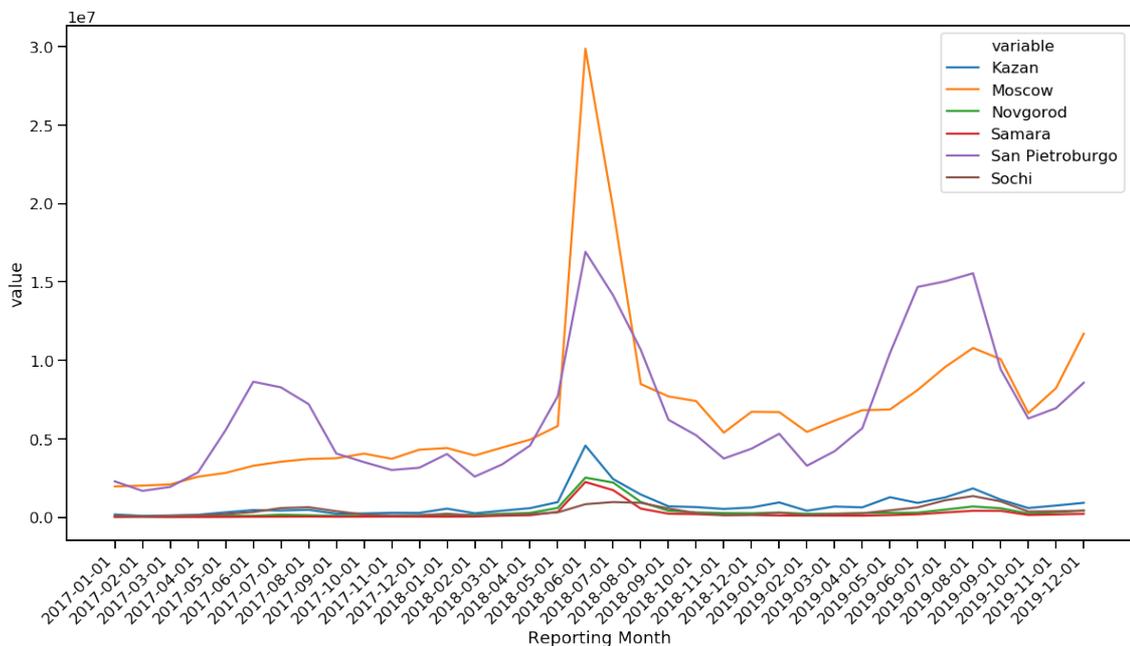
**Tabella 6** Tasso di crescita del numero di prenotazioni nelle sei città in esame

Le stesse evidenze empiriche (stagionalità e trend) riscontrate per il numero di reservation sono state osservate anche per il numero di giorni in cui un appartamento risultava prenotato sulla piattaforma (Figura 4.10).



**Figura 4.10** Andamento del numero di giorni prenotati nelle sei città in esame

Effettuando uno studio dei ricavi complessivi della piattaforma, il Mondiale di calcio del 2018 si conferma come un evento unico e irripetibile dal punto di vista economico, in quanto tutte le città presentano un picco in corrispondenza dell'avvio dell'evento (Figura 4.11). Sorprendentemente, nel solo mese di Giugno 2018 la somma dei ricavi complessivi di tutte le città prese in esame, senza considerare Mosca, è di 27.125.649,47\$. A parità di mese, tale valore viene superato dal ricavo complessivo della capitale russa (29.869.198,53\$).

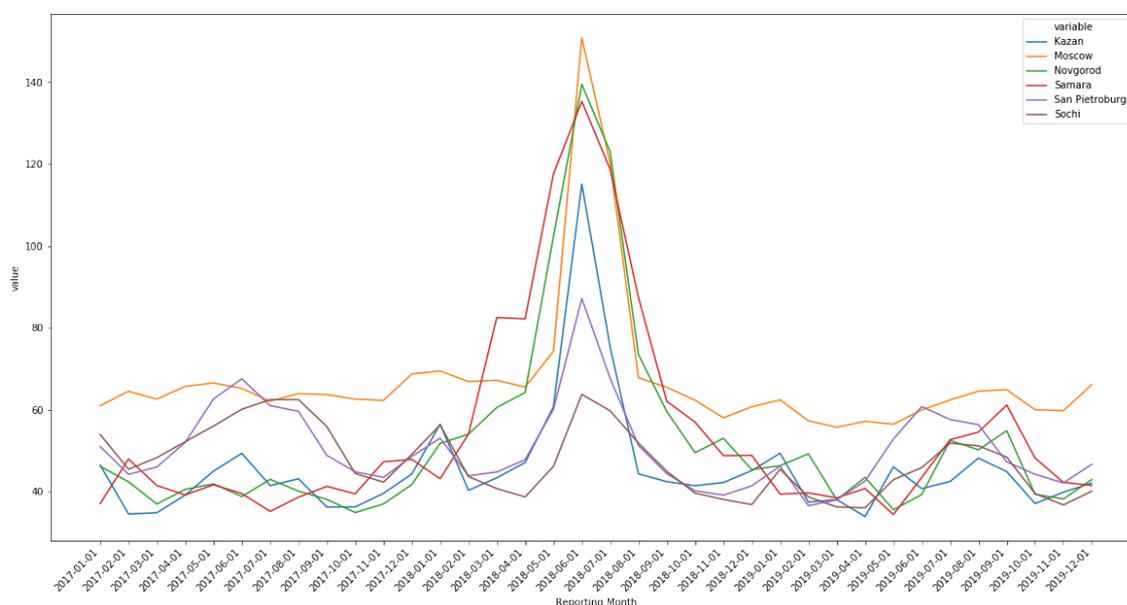


**Figura 4.11** Andamento dei ricavi nelle sei città in esame

Anche in questo caso, analizzando il grafico, emerge il fenomeno di stagionalità, che risulta particolarmente accentuato per San Pietroburgo, a differenza delle altre città. Durante

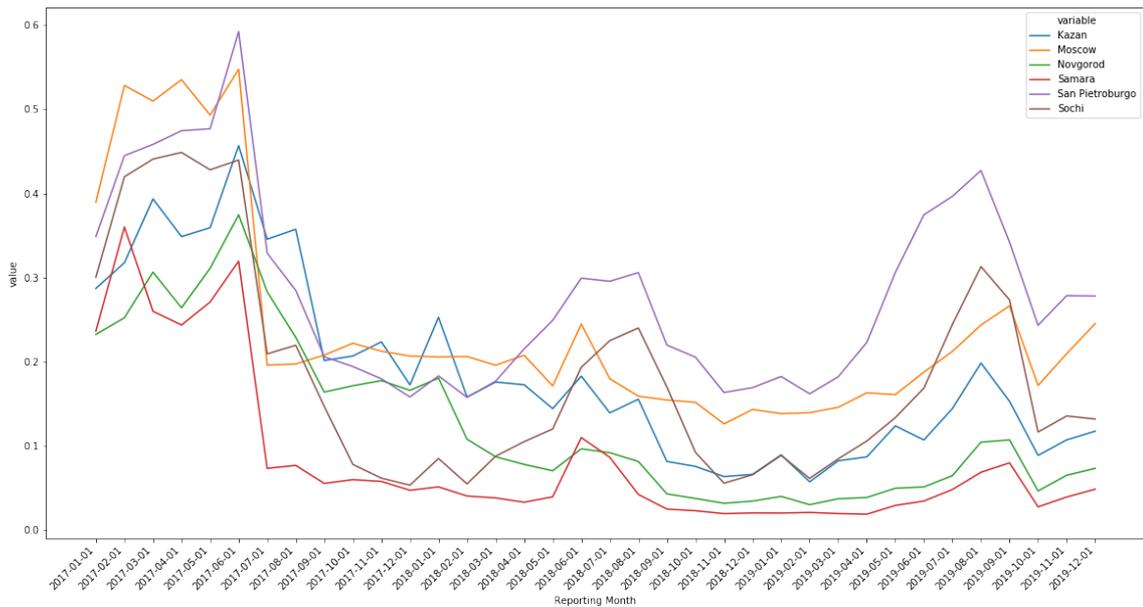
il periodo del Mondiale (Maggio, Giugno e Luglio 2018), a Mosca e a Samara si rileva il maggiore incremento percentuale di ricavi mensili pari al 413% e 543%, rispettivamente.

L'impatto economico del Mondiale in tutte le città appare più evidente se viene considerato il ricavo medio mensile (Figura 4.12), calcolato come rapporto dei ricavi mensili sul numero di giorni prenotati nello stesso mese. Nel primo semestre del 2018, la crescita dei ricavi medi mensili è stata registrata maggiormente per la città di Mosca e per quasi tutte le città "periferiche", ad esclusione delle città di San Pietroburgo e di Sochi. Inoltre, tra le città "metropolitane", Mosca riporta una variazione percentuale positiva del 117,0% nel primo semestre del 2018, a differenza di San Pietroburgo che non riesce ad eguagliare le performance economiche della capitale (56,7%).



**Figura 4.12** Andamento dei ricavi medi mensili nelle sei città in esame

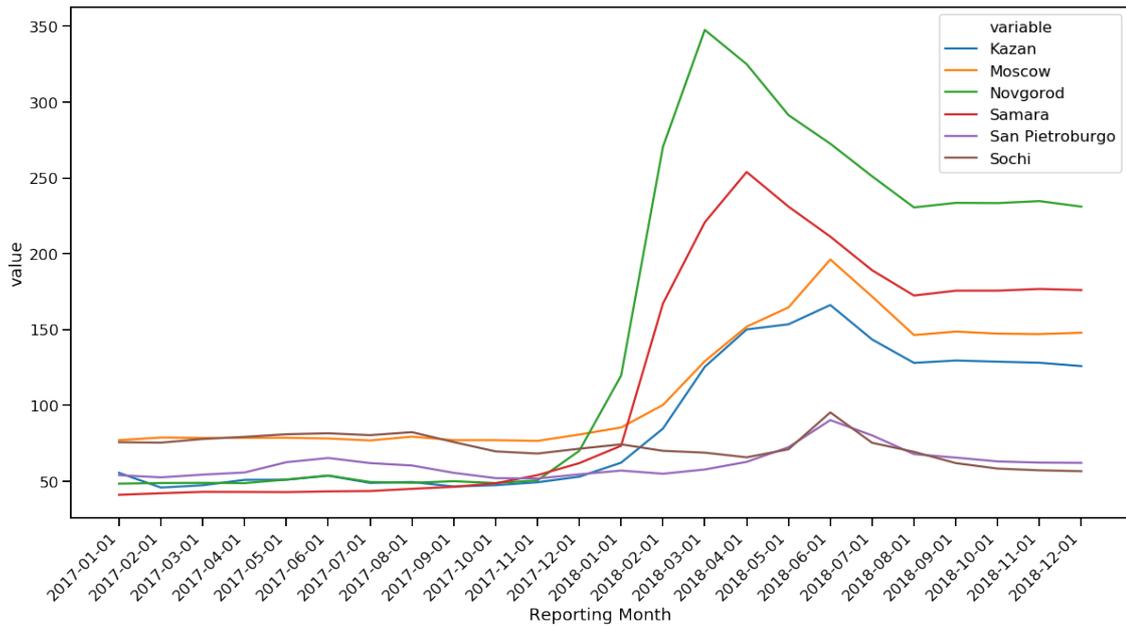
Interessante è l'analisi dell'andamento degli Occupation Rate delle diverse città. Come già definito nel capitolo precedente, l'Occupation Rate è una misura che indica il tasso di occupazione dell'alloggio. Nella Figura 4.11 si può notare un drastico calo dell'Occupation Rate a Maggio e a Giugno 2017, periodo in cui si è svolta la Confederation Cup.



**Figura 4.13** Andamento Occupation Rate nelle sei città in esame

La diminuzione del tasso in quei mesi è probabilmente da associarsi al notevole aumento del numero di proprietà proposte sulla piattaforma da parte degli host, i quali sono stati attratti dal presunto ritorno economico derivante dalla manifestazione calcistica. A differenza di tale scenario, nonostante la crescita esponenziale dei nuovi annunci, è stato riscontrato un effetto positivo sull'Occupation Rate per le città di San Pietroburgo, Mosca, Samara e Sochi durante la competizione del Mondiale.

Focalizzando l'attenzione sul periodo interessato dal Mondiale di Calcio, è stato valutato l'andamento del prezzo medio mensile nelle città in campione (Figura 4.14). Nel primo semestre del 2018, l'incremento percentuale del prezzo per Samara, Kazan, Mosca e Novgorod è stato considerevole (rispettivamente pari a 187,7%, 166,8%, 129,5% e 127,7%). Nonostante la fine della competizione del Mondiale, i prezzi medi mensili si sono stabilizzati intorno a una quota superiore, se confrontati con quelli del 2017.



**Figura 4.14** Andamento del prezzo medio nelle sei città in esame

Da tale osservazione, si può affermare che i ricavi generati dalla piattaforma durante il periodo del Mondiale siano frutto di due fattori principali: un lieve aumento dell'Occupation Rate e un vertiginoso incremento dei prezzi medi mensili.

In conclusione, il Mondiale di Calcio del 2018 è stato un mezzo di sviluppo e diffusione per la piattaforma Airbnb in quanto nell'anno successivo si ravvede un trend di crescita di tutte le variabili, anche nelle città meno conosciute.

# Capitolo 5

## EVENT STUDY

La disamina descrittiva è stata utile per avere una visione complessiva dell'evento del Mondiale di Calcio e il suo impatto sulle variabili economiche della piattaforma Airbnb. In questo capitolo sono stati applicati alcuni modelli presenti in letteratura con lo scopo di individuare quello che si adatta maggiormente al settore turistico. I modelli analizzati sono:

- 1) Constant Mean Return
- 2) Trend Model (Market Model)
- 3) Trend and Seasonality Model e Alternative

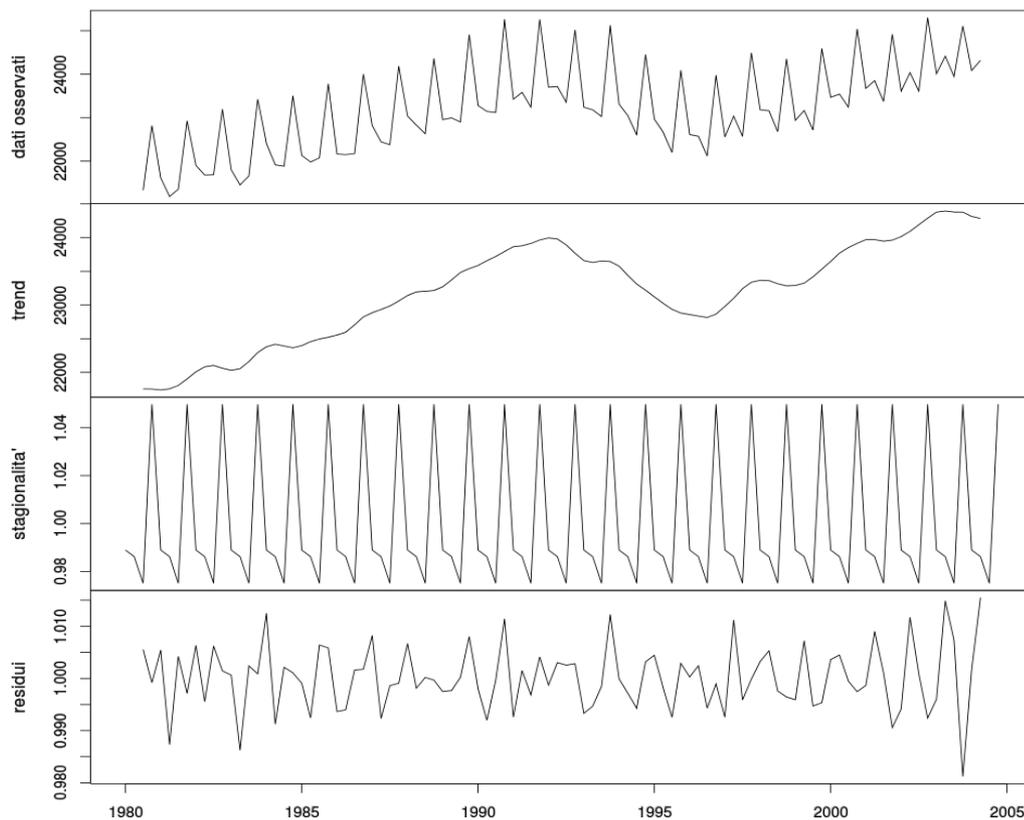
Prima di affrontare tale studio, si precisa che la variabile dipendente esaminata è a tutti gli effetti una serie storica, il cui indice corrisponde al tempo (giorni). Infatti, si può descrivere la variabile ADR come la somma di una componente deterministica (parte sistematica) e una sequenza di variabili aleatorie (parte stocastica).

$$ADR_t = f(t) + u_t$$

In particolare, la parte sistematica è la risultante di due componenti:

- Stagionalità (o componente stagionale), ovvero oscillazioni a cadenza periodica più o meno regolare.
- Trend (o componente tendenziale), evidenzia una evoluzione strutturale del fenomeno di lungo periodo.

È possibile raffigurare le suddette componenti per poter comprendere il loro andamento nel tempo (Figura 5.1).



**Figura 5.1** Andamento delle componenti strutturali e della componente aleatoria

I modelli considerati cercheranno di incorporare tutte le componenti non direttamente osservabili, al fine di sviluppare al meglio il nostro studio.

Nei paragrafi successivi è stata esaminata approfonditamente ogni singola metodologia, adattata al caso in esame, seguita dai risultati ottenuti. Per ovvie ragioni, si è preferito descrivere le metodologie applicandole al match finale del Mondiale a Mosca disputato il 15 Luglio 2018. Inoltre, per verificare se la tecnica utilizzata sia idonea al campione studiato, è stato svolto un breve confronto tra le città.

Si specifica che i modelli di regressione lineare applicati (Trend Model, Trend and Seasonality Model e Alternative) presentano due caratteristiche peculiari: eteroschedasticità del termine d'errore ed autocorrelazione dei residui. Per tale motivo si è deciso di correggere la matrice di varianza-covarianza dello stimatore tramite la correzione di Newey-West, in modo da rendere gli standard error consistenti (HAC, ovvero Heteroskedasticity and Autocorrelation Consistent). In allegato 6.4.4 è disponibile il codice per la stima della retta di regressione attraverso le librerie *Statsmodel* e *Sk.learn*.

### 5.1 Constant Mean Return

Una delle metodologie più semplici per poter stimare i ricavi medi giornalieri attesi è il Constant Mean Return (*Binder*, 1998). Negli articoli pubblicati sul Journal of Financial

Economics, Brown e Warner avvalorano la tesi della semplicità del suddetto modello, producendo dei risultati comparabili a quelli ottenuti con approcci più complessi.

Il Constant Mean Return presuppone che l'andamento della variabile analizzata, l'Average Daily Revenue atteso, sia costante (quindi indipendente nel tempo) e differente a seconda delle città in esame. Si ipotizza l'uguaglianza tra il ricavo medio giornaliero normale, registrato sulla piattaforma, e l'ADR medio calcolato durante l'Estimation Window. In particolare, è stato considerato un ADR normale, stimato negli stessi giorni dell'Event Window ma nell'anno antecedente del Mondiale di Calcio. Definendo  $\mu_i$  come l'ADR medio generato dagli host sulla piattaforma, è possibile calcolare il ricavo giornaliero medio come di seguito:

$$ADR_{it} = \mu_i + \varepsilon_{it}$$

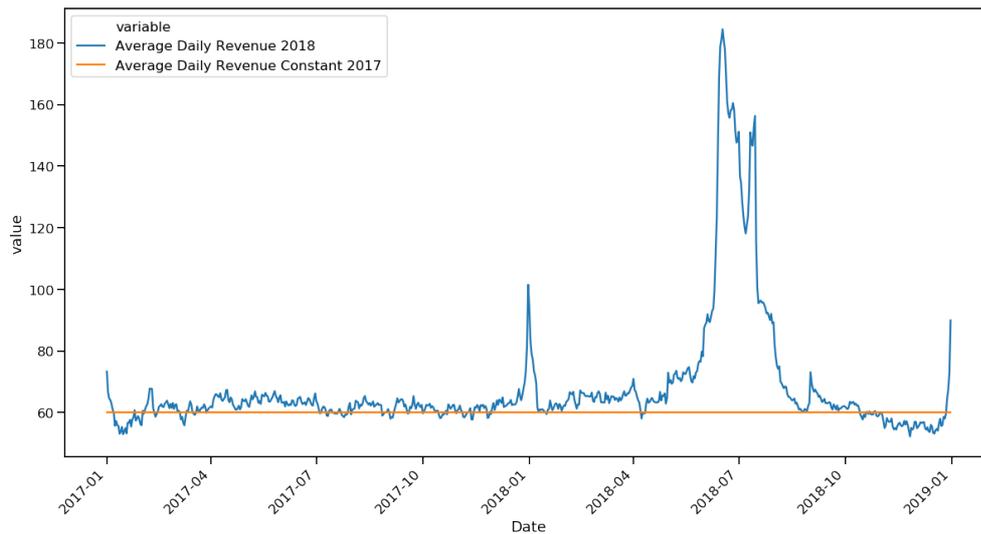
Le variabili del modello sono:

- $ADR_{it}$ , ricavo giornaliero medio della piattaforma nel periodo t nella città i
- $\varepsilon_{it}$ , termine di disturbo o errore

#### 5.1.1 Applicazione e risultati

Seguendo il procedimento descritto, è stato scelto un Event Window della durata di dodici giorni [-3; +8] che va da 3 giorni prima a 8 giorni dopo l'evento, riconducibile alla Finale di Mosca del 15 Luglio 2018.

Successivamente è stato considerato un Estimation Window della stessa durata dell'Event Window ma nell'anno precedente, quindi un arco temporale di 12 giorni. Pertanto, il primo giorno osservato è stato il 12 Luglio del 2017, mentre l'ultimo giorno il 23 Luglio. L'Average Daily Revenue normale è stato calcolato come la media algebrica degli Average Daily Revenue osservati durante l'Estimation Window. Una volta quantificato, è stato possibile costruire un grafico di confronto con i valori dei ricavi medi giornalieri osservati nella città di Mosca in un arco temporale di due anni (Figura 5.2).

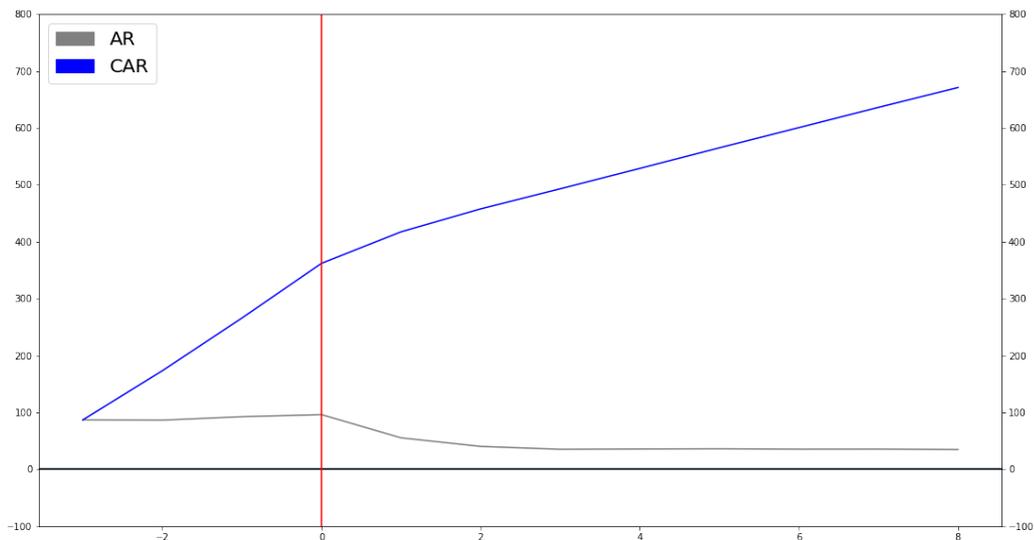


**Figura 5.2** Andamento dell'Average Daily Revenue effettivo e costante per la città di Mosca

A questo punto dell'analisi è stato possibile calcolare gli AR, i CAR e il Test di student, con lo scopo di verificare la significatività dei singoli AR. La Tabella 7 consente di avere una panoramica generale di tutte le variabili stimate e di trarre dei commenti a riguardo. Come si può notare, sono stati registrati degli AR positivi e importanti per la variabile analizzata (Figura 5.3). Con un intervallo di confidenza del 95%, è stata rilevata una significatività statistica nei giorni precedenti dell'evento, ma anche per il giorno stesso e il giorno successivo. Infatti, si osserva come il giorno dell'evento abbia ricavi medi giornalieri significativamente maggiori rispetto a qualunque altro giorno. Nei giorni successivi all'evento si può constatare che gli ADR sono inferiori (stabilizzati sui 95\$).

Period	Average Daily Revenue 2018	Average Daily Revenue Constant 2017	AR	CAR	Std.dev. AR	T-Test	Significant
-3	147.107923	60.212889	86.895034	86.895034	26.259334	3.309110	Si
-2	146.657578	60.212889	86.444689	173.339723	26.259334	3.291960	Si
-1	152.742503	60.212889	92.529614	265.869337	26.259334	3.523685	Si
0	156.340039	60.212889	96.127151	361.996488	26.259334	3.660685	Si
1	115.530372	60.212889	55.317483	417.313971	26.259334	2.106584	Si
2	100.518270	60.212889	40.305382	457.619352	26.259334	1.534897	None
3	95.520952	60.212889	35.308063	492.927415	26.259334	1.344591	None
4	96.028071	60.212889	35.815182	528.742597	26.259334	1.363903	None
5	96.384271	60.212889	36.171383	564.913980	26.259334	1.377468	None
6	95.714201	60.212889	35.501312	600.415292	26.259334	1.351950	None
7	95.821888	60.212889	35.609000	636.024292	26.259334	1.356051	None
8	95.054679	60.212889	34.841790	670.866082	26.259334	1.326834	None

**Tabella 7**



**Figura 5.3** AR, CAR per la città di Mosca

Negli allegati 6.7 è possibile osservare i risultati ottenuti per le altre città russe durante le gare selezionate. Interessante notare come la maggior parte delle città analizzate abbiano risentito dell'impatto dell'evento sulla variabile ADR mostrando nell'Event Window degli Abnormal Return significativi nello stesso giorno, a esclusione della città di Sochi. In particolare, lo scarto tra ADR effettivi e ADR attesi per le città di Novgorod e Samara è alquanto rilevante, difatti ogni giorno dell'Event Window risulta significativo.

Questo primo modello sembra rispondere adeguatamente alla domanda di ricerca, in quanto riesce a risolvere il problema della stagionalità considerando lo stesso periodo dell'anno precedente per l'Estimation Window. Tuttavia, il Constant Mean Return risulta inadeguato a cogliere la componente tendenziale dei ricavi giornalieri medi.

## 5.2 Trend Model

Nel caso in esame è stato sfruttato il principio teorico che sta alla base del Market Model, ovvero la regressione lineare semplice, per poter stimare il coefficiente della componente tendenziale dell'ADR effettivo. La formula utilizzata è la seguente:

$$ADR_{it} = \alpha + \beta Trend_{it} + \varepsilon_{it}$$

In cui:

- $ADR_{it}$  è il ricavo giornaliero medio della piattaforma nel periodo t nella città i
- $\alpha$  è l'intercetta dell'analisi di regressione

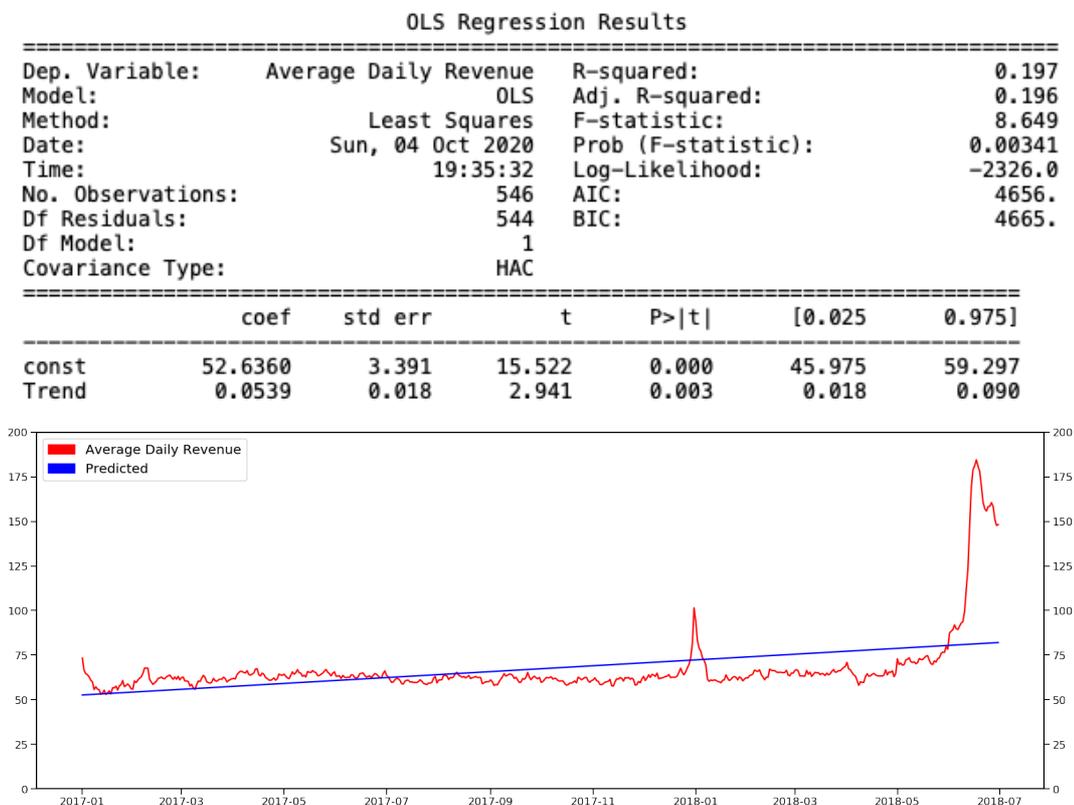
- $Trend_{it}$  simula la componente tendenziale ed è caratterizzata da una serie progressiva di numeri. La variabile assume valore 1 nel primo giorno di osservazione e valori progressivi nei giorni successivi.
- $\varepsilon_{it}$  è il termine di disturbo o errore

Il coefficiente  $\beta$  indica l'effetto atteso sulla variabile dipendente di una alterazione unitaria della variabile indipendente. Nello specifico, tale coefficiente è stato calcolato durante l'Estimation Window, che copre un arco temporale pari a 18 mesi precedente all'avvio dei Quarti del Mondiale (inizio dei dati osservati 1° Gennaio 2017). Un maggior numero di dati, ad esempio ampliando l'Estimation Window agli anni antecedenti al 2017, avrebbe consentito di ottenere stime più precise; tuttavia ciò non è stato possibile data la limitata capacità di calcolo.

### 5.2.1 Applicazione e risultati

In questo modello, l'Estimation Window inizia il 1° gennaio 2017 e termina il 30 Giugno 2018.

Analizzando la Figura 5.4, si può osservare l'output prodotto dalla libreria *Statsmodels* per quanto riguarda la retta di regressione semplice stimata.



**Figura 5.4** Stima della retta di regressione ADR attraverso il Trend Model per la città di Mosca

Come si può notare dai coefficienti generati, il coefficiente del Trend risulta positivo nella capitale russa, indicando una crescita, seppur di modesta entità, del mercato di Airbnb (Figura 5.4).

È necessario dare una interpretazione del coefficiente  $\beta$  per poter comprendere il suo significato. Questo esprime l'attitudine dell'ADR a variare in funzione del Trend. Se  $\beta > 0$ , significa che l'ADR cresce linearmente nel tempo; al contrario, se  $\beta < 0$ , la variabile diminuisce.

Una volta stimata la retta di regressione, è possibile predire i valori degli ADR normali della città in esame durante l'Event Window, visualizzabili nella Figura 5.5. È evidente come i risultati ottenuti tramite il T-Test siano simili a quelli prodotti nel modello Constant Mean Return; tuttavia, il giorno successivo all'Event Day non risulta più significativo.

Period	Average Daily Revenue	Predicted	Date	AR	CAR	Std.dev. AR	T-Test	Significant
-3	147.107923	82.710961	2018-07-12	64.396962	64.396962	26.426761	2.436809	Si
-2	146.657578	82.764859	2018-07-13	63.892719	128.289681	26.426761	2.417728	Si
-1	152.742503	82.818756	2018-07-14	69.923747	198.213427	26.426761	2.645945	Si
0	156.340039	82.872654	2018-07-15	73.467385	271.680813	26.426761	2.780037	Si
1	115.530372	82.926552	2018-07-16	32.603820	304.284633	26.426761	1.233743	None
2	100.518270	82.980450	2018-07-17	17.537821	321.822453	26.426761	0.663639	None
3	95.520952	83.034347	2018-07-18	12.486604	334.309058	26.426761	0.472498	None
4	96.028071	83.088245	2018-07-19	12.939826	347.248883	26.426761	0.489649	None
5	96.384271	83.142143	2018-07-20	13.242129	360.491012	26.426761	0.501088	None
6	95.714201	83.196041	2018-07-21	12.518160	373.009172	26.426761	0.473693	None
7	95.821888	83.249938	2018-07-22	12.571950	385.581123	26.426761	0.475728	None
8	95.054679	83.303836	2018-07-23	11.750843	397.331966	26.426761	0.444657	None

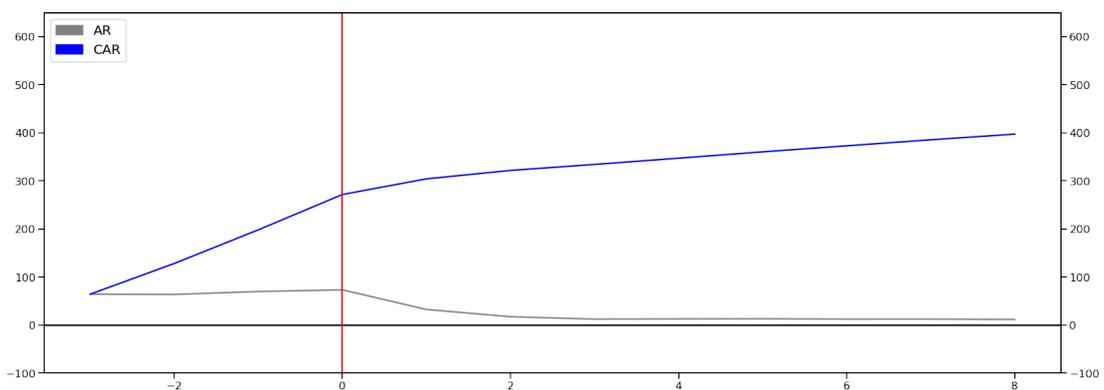


Figura 5.5 AR, CAR, T-Test per la città di Mosca

Negli allegati 6.8 sono stati raccolti i risultati ottenuti per le restanti città russe durante le gare selezionate. È stato riscontrato un coefficiente del Trend positivo per la quasi totalità del campione (tranne per la città di Sochi), che sta ad indicare una crescita dei ricavi medi

giornalieri nel tempo. Infatti, per la città di Sochi, l'andamento dei valori predetti è in continua decrescita determinando una significatività dell'intera Event Window.

Questo secondo modello riesce a spiegare la componente tendenziale degli ADR nelle città in esame, ma non ha la capacità di individuare il fenomeno della stagionalità, riportato nel modello precedente. Per tale motivo, si è deciso di introdurre un ulteriore modello (il Trend and Seasonality Model) che fosse in grado di incorporare sia la componente tendenziale che quella stagionale.

### 5.3 Trend and Seasonality Model

Si tratta di un modello statistico di regressione lineare multipla caratterizzato dalla presenza di variabili dummy, che consente di stimare gli Average Daily Revenue attesi. Il modello matematico alla base di una time series è il seguente:

$$y_t = f(S_t, T_t, e_t)$$

Dove:

- $y_t$  è la variabile dipendente riferito al periodo  $t$
- $S_t$  simula la componente stagionale al periodo  $t$
- $T_t$  simula la componente tendenziale al periodo  $t$
- $e_t$  è la componente aleatoria al periodo  $t$

Per studiare la forma di  $f()$  sono stati introdotti due approcci differenti:

- Il modello additivo: risulta appropriato quando l'ampiezza dell'oscillazione stagionale non cambia col variare del livello della serie.

$$y_t = S_t + T_t + e_t$$

- Il modello moltiplicativo: viene sfruttato nel caso in cui la fluttuazione stagionale aumenta (o diminuisce) proporzionalmente all'aumento (o diminuzione) del livello della serie.

$$y_t = S_t * T_t * e_t$$

La figura 5.6 è una rappresentazione grafica che mette in evidenza le peculiarità di due serie storiche differenti e consente di stabilire il modello idoneo da applicare.

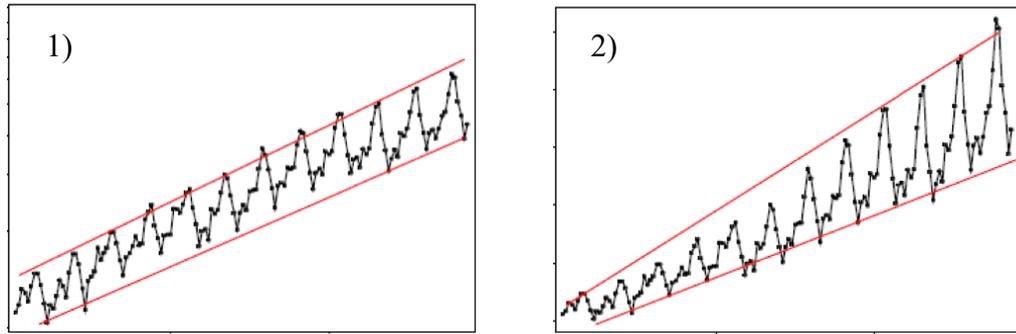


Figura 5.6 Rappresentazione delle serie storiche: 1) modello additivo 2) modello moltiplicativo

In questo lavoro è stato trattato esclusivamente il modello additivo poiché può essere applicato anche al modello moltiplicativo, in seguito a un'opportuna trasformazione logaritmica dei dati.

Le equazioni generali dei modelli citati, considerando anche la trasformazione logaritmica, si presentano così:

$$ADR_{it} = \alpha + \beta_1 Trend_{it} + \sum \beta_i Month_i + \sum \beta_i Day_i + \varepsilon_{it}$$

$$\ln(ADR_{it}) = \alpha + \beta_1 Trend_{it} + \sum \beta_i Month_i + \sum \beta_i Day_i + \varepsilon_{it}$$

Le variabili introdotte sono:

- $ADR_{it}$ , corrisponde al ricavo giornaliero medio della piattaforma nel periodo  $t$  nella città  $i$
- $\alpha$ , è l'intercetta dell'analisi di regressione
- $Trend_{it}$ , simula la componente tendenziale ed è caratterizzata da una serie progressiva di numeri. La variabile assume valore 1 nel primo giorno di osservazione e valori progressivi nei giorni successivi
- $Month_i$ , si tratta della variabile binaria che simula la componente stagionale mensile. Sono state considerate 11 variabili dummy, che ciascuna rappresenta un mese di riferimento (a esclusione del mese di Febbraio). Ad esempio, la variabile *gen* assume valore 1 nel caso in cui la rilevazione sia stata eseguita nel mese di Gennaio.
- $Day_i$ , è la variabile binaria che simula la componente stagionale giornaliera. Sono state considerate 6 variabili dummy, che ciascuna rappresenta un giorno di riferimento (a esclusione del Martedì). Ad esempio, la variabile *dom* assume valore 1 nel caso in cui la rilevazione sia stata effettuata di Domenica.
- $\varepsilon_{it}$ , è il termine di disturbo o errore

### 5.3.1 Applicazione e risultati

Di seguito viene proposto l'output prodotto dalla libreria *Statsmodel* relativo al modello in questione. In tal caso è stata analizzata la variabile dipendente ADR, senza considerare la sua trasformazione logaritmica. Come è stato accennato in precedenza, nell'indagine non sono stati inclusi il mese di Febbraio e il giorno Mercoledì al fine di non incorrere nella trappola delle variabili dummy.

OLS Regression Results						
Dep. Variable:	Average Daily Revenue		R-squared:	0.532		
Model:	OLS		Adj. R-squared:	0.516		
Method:	Least Squares		F-statistic:	37.15		
Date:	Sun, 04 Oct 2020		Prob (F-statistic):	1.12e-81		
Time:	23:16:32		Log-Likelihood:	-2175.8		
No. Observations:	546		AIC:	4390.		
Df Residuals:	527		BIC:	4471.		
Df Model:	18					
Covariance Type:	HAC					
	coef	std err	t	P> t	[0.025	0.975]
const	54.7315	3.386	16.164	0.000	48.080	61.383
Trend	0.0387	0.011	3.409	0.001	0.016	0.061
gen	-0.7490	2.868	-0.261	0.794	-6.383	4.885
mar	-1.8595	2.519	-0.738	0.461	-6.809	3.090
apr	-2.0884	3.212	-0.650	0.516	-8.398	4.221
mag	3.8455	2.961	1.299	0.195	-1.971	9.662
giu	35.1462	11.182	3.143	0.002	13.180	57.113
lug	10.0455	2.087	4.813	0.000	5.945	14.146
ago	1.8481	2.744	0.673	0.501	-3.543	7.239
set	-2.8943	2.107	-1.374	0.170	-7.033	1.244
ott	-5.0668	2.183	-2.321	0.021	-9.355	-0.779
nov	-6.6097	2.290	-2.886	0.004	-11.108	-2.111
dic	-2.4235	3.166	-0.766	0.444	-8.643	3.796
lun	0.6898	0.813	0.848	0.397	-0.908	2.288
mer	0.0438	0.608	0.072	0.943	-1.151	1.239
gio	0.2315	0.656	0.353	0.724	-1.057	1.520
ven	-0.1230	0.833	-0.148	0.883	-1.759	1.513
sab	-0.2763	0.918	-0.301	0.764	-2.080	1.527
dom	-0.1561	1.022	-0.153	0.879	-2.163	1.851

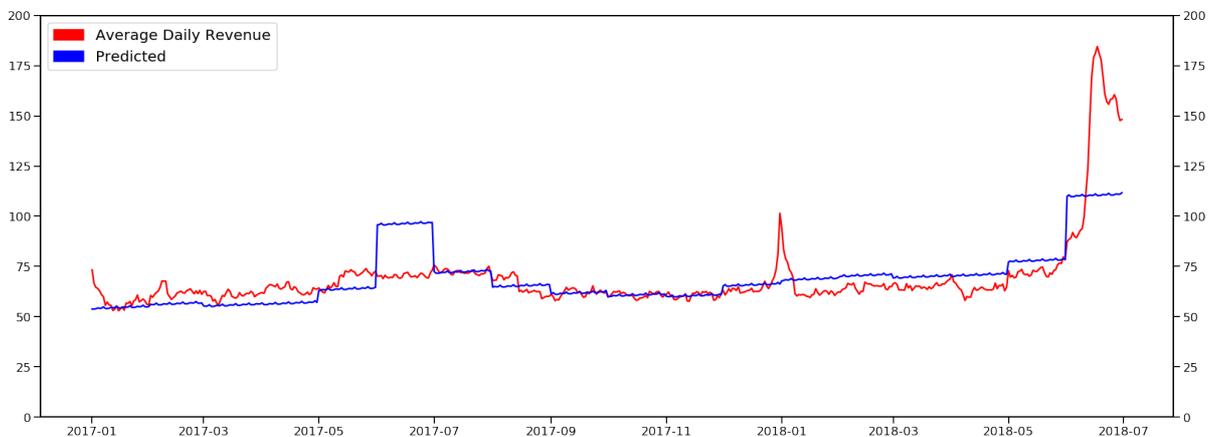


Figura 5.7 Stima della retta di regressione attraverso il Trend and Seasonality Model per la città di Mosca

Sin da una prima analisi è evidente che si tratti di un modello moltiplicativo dato che la componente stagionale non viene catturata nel modo giusto. Difatti, come è possibile osservare in Figura 5.7, le fluttuazioni stagionali aumentano con il livello della serie.

Una volta stimata la retta di regressione, è possibile predire i valori degli ADR normali della città in esame durante l'Event Window, visualizzabili nella Figura 5.8. È evidente come i risultati ottenuti con il T-Test siano uguali a quelli prodotti nel modello Trend Model, anche se i valori predetti risultano esser maggiori, attestandosi sui 87\$. L'introduzione delle variabili binarie stagionali (mensili e giornaliere) ha consentito di catturare il fenomeno di stagionalità, soprattutto per quelle città che risentono di tale problematica (Mosca, San Pietroburgo e Sochi).

Period	Average Daily Revenue	Predicted	Date	AR	CAR	Std.dev. AR	T-Test	Significant
-3	147.107923	86.378548	2018-07-12	60.729375	60.729375	26.341124	2.305497	Si
-2	146.657578	86.461034	2018-07-13	60.196543	120.925919	26.341124	2.285269	Si
-1	152.742503	87.145798	2018-07-14	65.596705	186.522624	26.341124	2.490277	Si
0	156.340039	86.338537	2018-07-15	70.001502	256.524126	26.341124	2.657499	Si
1	115.530372	86.257128	2018-07-16	29.273244	285.797370	26.341124	1.111313	None
2	100.518270	86.449101	2018-07-17	14.069169	299.866540	26.341124	0.534114	None
3	95.520952	86.842307	2018-07-18	8.678644	308.545184	26.341124	0.329471	None
4	96.028071	86.649534	2018-07-19	9.378537	317.923721	26.341124	0.356042	None
5	96.384271	86.732020	2018-07-20	9.652251	327.575972	26.341124	0.366433	None
6	95.714201	87.416784	2018-07-21	8.297417	335.873390	26.341124	0.314999	None
7	95.821888	86.609523	2018-07-22	9.212365	345.085755	26.341124	0.349733	None
8	95.054679	86.528114	2018-07-23	8.526565	353.612320	26.341124	0.323698	None

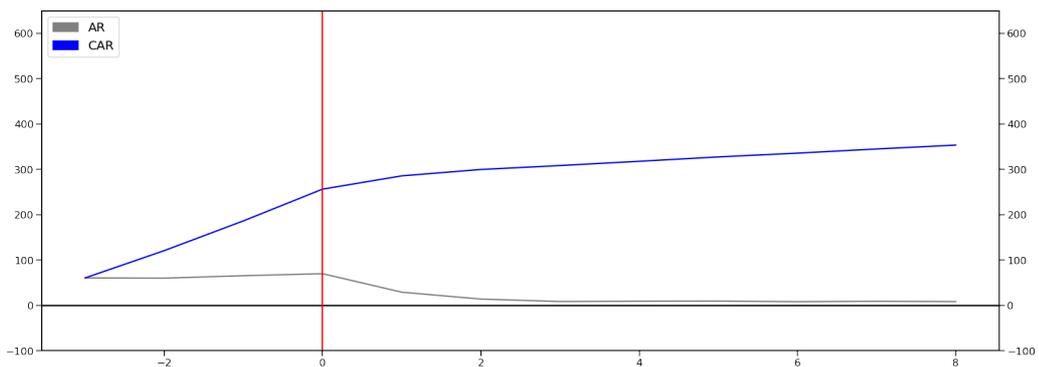


Figura 5.8 AR, CAR, T-Test per la città di Mosca

I risultati riguardanti le altre città interessate dalle gare calcistiche selezionate sono disponibili negli allegati 6.9. Importante notare come le stime per le città di San Pietroburgo e Sochi abbiano prodotto dei risultati differenti da quelli ottenuti con modelli precedenti. Nel caso di San Pietroburgo, l'unica significatività è riscontrabile per il giorno -3 dell'Event

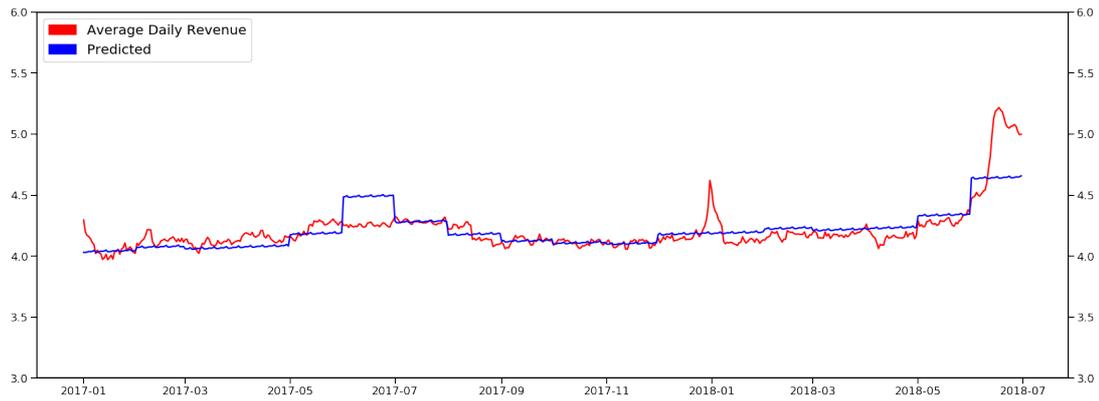
Window con un intervallo di confidenza del 95%. Due eventi possono aver influenzato e prodotto questo risultato: la Finale di 3° e 4° posto e la semifinale disputata il 10 luglio.

Invece, per quanto riguarda Sochi, i risultati generati dal T-Test differiscono totalmente da quelli ottenuti con gli altri modelli in quanto si evidenzia una significatività per il giorno stesso dell'evento e quello antecedente.

Anche in questo ultimo modello, l'impatto dei Quarti di finale nelle città di Novgorod e Samara è stato rilevante al punto tale da osservare una significatività statistica per tutti i giorni analizzati, anche se i valori predetti sono inferiori quando confrontati con quelli del Trend Model. Questo probabilmente dipende dall'elevato coefficiente stimato per la variabile Trend e dal trascurabile coefficiente di Luglio (addirittura negativo per la città di Samara, indice di fenomeno stagionalità non presente nei mesi estivi). Inoltre, gli ADR attesi per la città di Kazan nell'ultimo modello sono piuttosto simili a quelli del Trend Model, i quali si attestano intorno ai 60\$.

Infine, è stata valutato il logaritmo della variabile dipendente ADR con lo scopo di incorporare le fluttuazioni stagionali in funzione del livello della serie. Infatti, come si evince dall'output prodotto da *Statsmodel*, gli indici  $R^2$  e  $R^2$  corretto hanno dei valori maggiori, confermando la bontà di adattamento del modello (Figura 5.9).

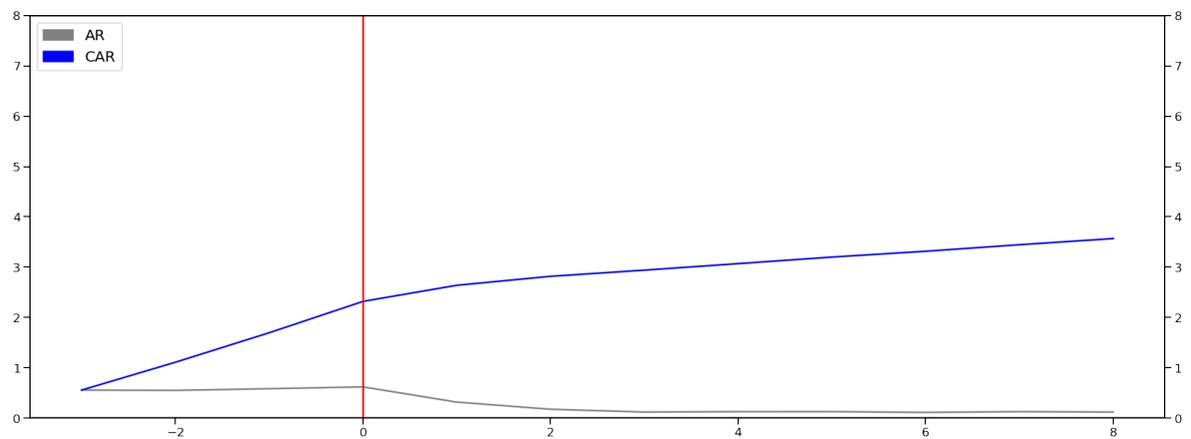
OLS Regression Results						
Dep. Variable: ln(Average Daily Revenue)			R-squared:	0.611		
Model: OLS			Adj. R-squared:	0.598		
Method: Least Squares			F-statistic:	43.44		
Date: Mon, 05 Oct 2020			Prob (F-statistic):	8.55e-92		
Time: 13:22:15			Log-Likelihood:	386.52		
No. Observations: 546			AIC:	-735.0		
Df Residuals: 527			BIC:	-653.3		
Df Model: 18						
Covariance Type: HAC						
	coef	std err	t	P> t	[0.025	0.975]
const	4.0572	0.031	129.265	0.000	3.996	4.119
Trend	0.0004	0.000	4.100	0.000	0.000	0.001
gen	-0.0235	0.032	-0.731	0.465	-0.087	0.040
mar	-0.0240	0.024	-1.014	0.311	-0.071	0.023
apr	-0.0211	0.034	-0.626	0.532	-0.087	0.045
mag	0.0711	0.030	2.362	0.019	0.012	0.130
giu	0.3643	0.097	3.737	0.000	0.173	0.556
lug	0.1436	0.021	6.889	0.000	0.103	0.185
ago	0.0272	0.034	0.796	0.426	-0.040	0.094
set	-0.0398	0.022	-1.820	0.069	-0.083	0.003
ott	-0.0683	0.022	-3.092	0.002	-0.112	-0.025
nov	-0.0870	0.023	-3.844	0.000	-0.132	-0.043
dic	-0.0199	0.036	-0.554	0.580	-0.090	0.051
lun	0.0096	0.008	1.241	0.215	-0.006	0.025
mer	0.0022	0.006	0.379	0.705	-0.009	0.014
gio	0.0020	0.006	0.323	0.747	-0.010	0.014
ven	-0.0025	0.008	-0.321	0.749	-0.018	0.013
sab	-0.0048	0.009	-0.554	0.580	-0.022	0.012
dom	-0.0039	0.010	-0.397	0.692	-0.023	0.015



**Figura 5.9** Stima della retta di regressione attraverso il Trend and Seasonality Model per la città di Mosca considerando il  $\ln(\text{ADR})$

I risultati del T-Test sono del tutto comparabili a quelli ottenuti nel caso precedente (Figura 5.10).

Period	Average Daily Revenue	Predicted	Date	AR	CAR	Std.dev. AR	T-Test	Significant
-3	4.991166	4.432413	2018-07-12	0.558753	0.558753	0.216521	2.580594	Si
-2	4.988100	4.435052	2018-07-13	0.553048	1.111802	0.216521	2.554245	Si
-1	5.028754	4.442849	2018-07-14	0.585904	1.697706	0.216521	2.705991	Si
0	5.052033	4.429737	2018-07-15	0.622296	2.320002	0.216521	2.874065	Si
1	4.749533	4.429228	2018-07-16	0.320305	2.640307	0.216521	1.479325	None
2	4.610340	4.432010	2018-07-17	0.178329	2.818636	0.216521	0.823610	None
3	4.559346	4.436936	2018-07-18	0.122410	2.941046	0.216521	0.565349	None
4	4.564641	4.435319	2018-07-19	0.129322	3.070368	0.216521	0.597272	None
5	4.568343	4.437958	2018-07-20	0.130385	3.200754	0.216521	0.602183	None
6	4.561367	4.445755	2018-07-21	0.115612	3.316366	0.216521	0.533953	None
7	4.562491	4.432643	2018-07-22	0.129848	3.446214	0.216521	0.599702	None
8	4.554452	4.432134	2018-07-23	0.122319	3.568533	0.216521	0.564927	None



**Figura 5.10** AR, CAR, T-Test per la città di Mosca

### 5.3.2 Alternative Trend and Seasonality Model

Un modello alternativo di Trend and Seasonality Model è quello di includere l'Event Window all'interno dell'Estimation Window, così da non effettuare successive previsioni della variabile dipendente (*Binder, 1998; Oliveira et al., 2016*). In tal caso l'Estimation Window copre un arco temporale che va dal 1° Gennaio 2017 al 31 Dicembre 2018.

Le equazioni generali del modello, considerando anche la trasformazione logaritmica, sono le seguenti:

$$ADR_{it} = \alpha + \beta_1 Trend_{it} + \sum \beta_i Month_i + \sum \beta_i Day_i + \sum \beta_i Event_i + \varepsilon_{it}$$
$$\ln(ADR_{it}) = \alpha + \beta_1 Trend_{it} + \sum \beta_i Month_i + \sum \beta_i Day_i + \sum \beta_i Event_i + \varepsilon_{it}$$

Le variabili analizzate sono identiche a quelle del modello precedente; l'unica differenza sta nella presenza delle variabili dummy  $Event_i$ . Il coefficiente angolare stimato di quest'ultimo rispecchia l'AR del giorno considerato nell'Event Window: ad esempio la variabile binaria Event 0 assume valore 1 nel caso in cui la rilevazione venga effettuata durante l'Event Day.

### 5.3.3 Applicazione e risultati

Nella figura 5.11 viene mostrato l'output generato con la libreria *Statsmodel* relativo al modello in questione. In questo caso non è stata considerata la trasformazione logaritmica della variabile dipendente ADR e, per evitare di incappare nella trappola delle variabili binarie, nello studio sono stati esclusi il mese di Febbraio e il giorno Mercoledì.

OLS Regression Results

```

=====
Dep. Variable:   Average Daily Revenue   R-squared:      0.493
Model:          OLS                     Adj. R-squared: 0.471
Method:         Least Squares           F-statistic:    8.198e+05
Date:           Mon, 05 Oct 2020        Prob (F-statistic): 0.00
Time:           21:02:21                 Log-Likelihood: -2981.1
No. Observations: 730                   AIC:            6024.
Df Residuals:   699                     BIC:            6167.
Df Model:       30
Covariance Type: HAC
=====

```

	coef	std err	t	P> t	[0.025	0.975]
const	56.4283	2.552	22.108	0.000	51.417	61.440
Trend	0.0302	0.008	3.754	0.000	0.014	0.046
gen	-1.0195	2.411	-0.423	0.673	-5.754	3.715
mar	-1.5934	1.916	-0.832	0.406	-5.355	2.169
apr	-1.5787	2.617	-0.603	0.547	-6.717	3.559
mag	2.3383	1.856	1.260	0.208	-1.305	5.982
giu	32.6921	13.376	2.444	0.015	6.431	58.953
lug	14.0533	8.448	1.663	0.097	-2.534	30.641
ago	-4.9177	2.761	-1.781	0.075	-10.338	0.503
set	-7.0947	2.894	-2.452	0.014	-12.776	-1.413
ott	-10.1994	3.206	-3.181	0.002	-16.494	-3.905
nov	-13.5310	3.826	-3.536	0.000	-21.043	-6.019
dic	-10.8015	4.528	-2.385	0.017	-19.692	-1.911
lun	0.4908	0.808	0.608	0.544	-1.095	2.077
mer	0.0747	0.723	0.103	0.918	-1.345	1.494
gio	0.8419	0.909	0.926	0.355	-0.943	2.627
ven	0.3602	0.869	0.415	0.678	-1.345	2.066
sab	0.0739	0.902	0.082	0.935	-1.697	1.845
dom	0.2451	0.947	0.259	0.796	-1.614	2.105
Event -3	59.7638	9.096	6.570	0.000	41.905	77.623
Event -2	59.2085	9.082	6.519	0.000	41.377	77.040
Event -1	64.8472	9.029	7.182	0.000	47.120	82.574
Event 0	68.6601	9.166	7.491	0.000	50.664	86.656
Event 1	27.9914	9.143	3.061	0.002	10.040	45.943
Event 2	12.6628	9.190	1.378	0.169	-5.380	30.706
Event 3	7.1536	9.346	0.765	0.444	-11.195	25.502
Event 4	8.4724	9.121	0.929	0.353	-9.435	26.380
Event 5	8.7237	9.107	0.958	0.338	-9.156	26.603
Event 6	7.6074	9.054	0.840	0.401	-10.169	25.383
Event 7	7.9304	9.192	0.863	0.389	-10.116	25.977
Event 8	7.3042	9.169	0.797	0.426	-10.697	25.306

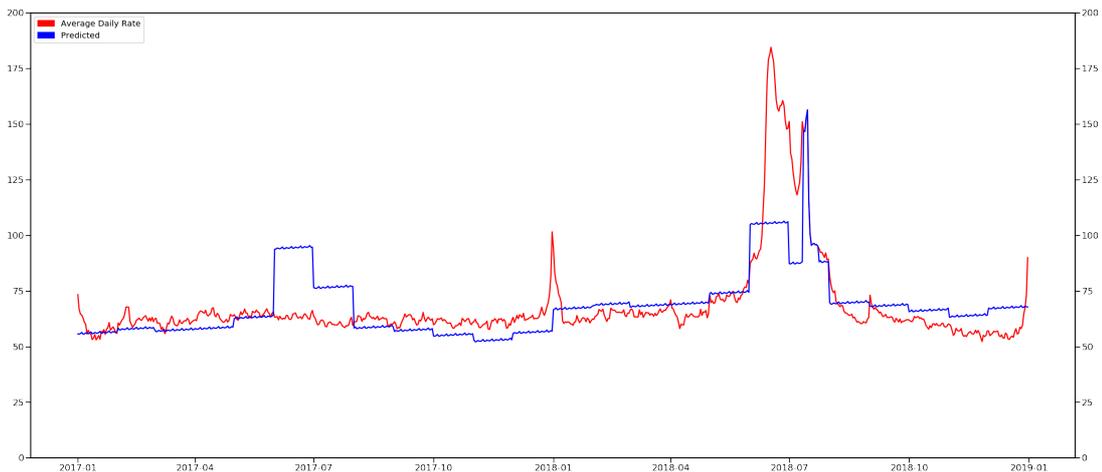


Figura 5.11 Stima della retta di regressione attraverso l'Alternative Trend and Seasonality Model per la città di Mosca

Inoltre, è stato valutato il logaritmo della variabile dipendente ADR al fine di incorporare le variazioni stagionali in funzione del livello della serie. Infatti, questo modello sembra

adattarsi in misura maggiore al caso esaminato in quanto gli indici  $R^2$  e  $R^2$  corretto hanno valori superiori (Figura 5.12).

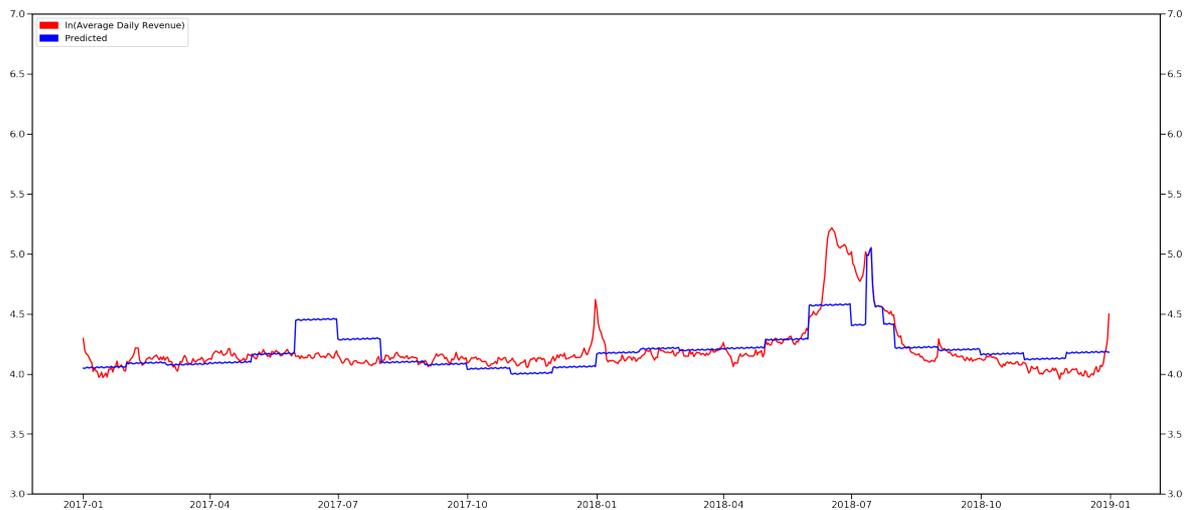
**OLS Regression Results**

---

Dep. Variable:	ln(Average Daily Revenue)	R-squared:	0.517
Model:	OLS	Adj. R-squared:	0.496
Method:	Least Squares	F-statistic:	7.398e+05
Date:	Tue, 06 Oct 2020	Prob (F-statistic):	0.00
Time:	19:39:22	Log-Likelihood:	368.61
No. Observations:	730	AIC:	-675.2
Df Residuals:	699	BIC:	-532.8
Df Model:	30		
Covariance Type:	HAC		

---

	coef	std err	t	P> t	[0.025	0.975]
const	4.0738	0.025	160.195	0.000	4.024	4.124
Trend	0.0003	8.11e-05	4.088	0.000	0.000	0.000
gen	-0.0262	0.029	-0.896	0.370	-0.083	0.031
mar	-0.0214	0.018	-1.191	0.234	-0.057	0.014
apr	-0.0161	0.028	-0.568	0.570	-0.072	0.040
mag	0.0454	0.018	2.521	0.012	0.010	0.081
giu	0.3222	0.124	2.602	0.009	0.079	0.565
lug	0.1495	0.094	1.588	0.113	-0.035	0.334
ago	-0.0528	0.030	-1.784	0.075	-0.111	0.005
set	-0.0813	0.030	-2.728	0.007	-0.140	-0.023
ott	-0.1259	0.034	-3.731	0.000	-0.192	-0.060
nov	-0.1775	0.044	-4.041	0.000	-0.264	-0.091
dic	-0.1336	0.055	-2.436	0.015	-0.241	-0.026
lun	0.0083	0.008	0.999	0.318	-0.008	0.025
mer	0.0032	0.007	0.432	0.666	-0.011	0.018
gio	0.0076	0.009	0.836	0.403	-0.010	0.025
ven	0.0023	0.009	0.259	0.795	-0.015	0.019
sab	-0.0016	0.009	-0.172	0.863	-0.020	0.017
dom	-0.0002	0.010	-0.019	0.985	-0.019	0.019
Event -3	0.5828	0.101	5.785	0.000	0.385	0.781
Event -2	0.5762	0.101	5.730	0.000	0.379	0.774
Event -1	0.6114	0.100	6.121	0.000	0.415	0.808
Event 0	0.6429	0.101	6.371	0.000	0.445	0.841
Event 1	0.3415	0.101	3.381	0.001	0.143	0.540
Event 2	0.1981	0.101	1.953	0.051	-0.001	0.397
Event 3	0.1414	0.103	1.375	0.169	-0.060	0.343
Event 4	0.1540	0.101	1.525	0.128	-0.044	0.352
Event 5	0.1541	0.101	1.529	0.127	-0.044	0.352
Event 6	0.1417	0.100	1.415	0.157	-0.055	0.338
Event 7	0.1510	0.101	1.493	0.136	-0.048	0.350
Event 8	0.1441	0.101	1.423	0.155	-0.055	0.343



**Figura 5.12** Stima della retta di regressione attraverso l'Alternative Trend and Seasonality Model per la città di Mosca considerando il ln (ADR)

Esaminando i risultati del T-Test, si osserva una significatività statistica anche per il giorno successivo a quello dell'evento, a differenza del Trend and Seasonality Model. Sicuramente, l'aver ampliato il periodo analizzato (2017 e 2018) ha permesso di stimare un coefficiente angolare di Luglio maggiore rispetto a quello calcolato nel solo anno 2017, ottenendo così degli AR minori. Per quanto riguarda le analisi delle restanti città (disponibili nell'allegato 6.9), i risultati di questo modello alternativo sono simili a quelli del Trend and Seasonality Model originale, mentre si differenziano da quelli delle altre metodologie.

Nonostante ciò, si conferma la significatività degli Event Day in tutto il campione con un intervallo di confidenza del 95%.

## CONCLUSIONI E SVILUPPI FUTURI

La tesi è stata strutturata in diverse fasi per poter affrontare la domanda di ricerca, ovvero quantificare l'impatto di alcuni match del Mondiale di Calcio del 2018 disputato in Russia.

Dopo aver introdotto le piattaforme e il fenomeno della *sharing economy*, è stata trattata approfonditamente la piattaforma Airbnb, la quale ha rivoluzionato il settore della ospitalità permettendo di far comunicare i due versanti del mercato, cioè gli host (venditori) con i guest (acquirenti).

Successivamente è stata svolta una robusta analisi descrittiva, preceduta da operazioni di estrazione e pulizia del dataset al fine di renderlo compatibile per il nostro studio. Si è constatato che l'evento calcistico ha favorito in modo evidente lo sviluppo e la diffusione del portale di Airbnb nel mercato russo, influenzando positivamente tutte le variabili (economiche e non) esaminate.

Per poter rispondere alla domanda di ricerca è stata applicata la metodologia Event Study Analysis, sfruttata nel settore finanziario, la cui utilità principale è quella di verificare se la variazione della variabile in esame sia significativa e sia influenzata dall'evento stesso. Per questo motivo è stata svolta una disamina approfondita della variabile di interesse, l'Average Daily Revenue, in quanto è caratterizzata da un trend e da una stagionalità, essendo una serie storica.

L'ultima fase del lavoro di tesi si presenta come una evoluzione continua: infatti, si è partiti con l'applicazione di un metodo molto diffuso in letteratura, il Constant Mean Return, per poi passare a un modello adattato alle esigenze del caso analizzato, il Trend and Seasonality Model. Ciò ha permesso di stimare gli ADR normali con diverse metodologie mettendo in risalto gli eventuali limiti e le relative correzioni. I primi modelli, ovvero il Constant Mean Return e il Trend Model, sono limitanti in quanto non riescono a catturare quei fenomeni peculiari (trend o stagionalità) della variabile di interesse. Gli altri modelli, ovvero il Trend and Seasonality Model e l'Alternative, rappresentano gli strumenti più adatti per spiegare l'impatto del singolo evento sui ricavi medi giornalieri della piattaforma Airbnb: mentre il primo consente di ottenere una previsione degli ADR normali nel mese dei match in esame, il secondo, includendo l'Event Window nell'Estimation Window, incorpora gli AR nella retta di regressione lineare multipla. In tabella 8, attraverso il Trend and Seasonality Model, è stato calcolato l'impatto netto delle partite di calcio nelle città in

esame. Naturalmente, il calcolo è approssimativo in quanto è risultato dal prodotto della differenza tra ADR effettivo e normale e il numero di annunci prenotati sulla piattaforma.

Mosca	San Pietroburgo	Nizhnij Novgorod	Kazan	Samara	Sochi
\$ 1.744.083,69	\$ 261.559,66	\$ 300.971,35	\$ 239.337,58	\$ 204.144,03	\$ 13.086,94

**Tabella 8** Impatto netto delle partite di calcio nelle città in esame

Quindi, sebbene in letteratura siano disponibili molteplici metodologie, l'Event Study Analysis si conferma un metodo di analisi valido per esaminare l'impatto prodotto da un evento sulle variabili economiche, da applicare eventualmente anche a settori completamente differenti, ad esempio quello turistico come nel caso studiato.

In futuro sarà utile da una parte individuare ulteriori metodologie da applicare alle serie storiche e dall'altra eseguire una analisi in cross-section valutando la significatività statistica di CAR e CAAR. In tal modo, ad esempio, si potrà comprendere se un Mega-Evento impatti esclusivamente sulla città di interesse o influenzi anche le zone limitrofe.

## BIBLIOGRAFIA

- Ádám Osztovits, Árpád Kószegi, Bence Nagy and Bence Damjanovics (2015). "Sharing or paring? Growth of the sharing economy".
- Armstrong, M. (2006). Competition in two-sided markets. *The RAND Journal of Economics*, 37(3), pp.668-691.
- Aznar A. Juan, and Sayeras M. Josep (2015). "The financial and economic performance of hotels in Spanish beach tourist destinations", in *Athens Journal of Tourism*, pp. 141-152.
- Aznar A. Juan, Sayeras M. Josep, Rocafort Alba and Galiana Jorge (2017). "The irruption of Airbnb and its effects on hotel profitability: An analysis of Barcelona's hotel sector".
- Ball R. and Brown P. (1968). "An Empirical Evaluation of Accounting Income Numbers.", in *Journal of Accounting Research*.
- Binder J. J. (1998). 'The Event Study Methodology Since 1969' in *Review of Quantitative Finance and Accounting*, Kluwer Academic Publishers, Boston, pp. 111–137.
- Benninga, S. (2008). "Financial modeling". Boston, MA: MIT Press, pp. 372.
- Chen Guangwu, Cheng Mingming, Deborah Edwards and Lixiao Xu (2020). "COVID-19 pandemic exposes the vulnerability of the sharing economy".
- Cheng Mingming and Foley Carmel (2018). "The sharing economy and digital discrimination: The case of Airbnb", in *International Journal of Hospitality Management*, pp.95-98.
- Christensen Clayton M. and Raynor Michael (2003). "The innovator's solution: Creating and sustaining successful growth" in Harvard Business School Press.
- Christensen Clayton M., Raynor Michael and McDonald Rory (2015). "What Is Disruptive Innovation?" in *Harvard Business Review* 93, no. 12 44–53.
- De Long J. Bradford and Froomkin A. Michael (1997). "The next Economy?"
- De Mauro Andrea, Greco Marco and Grimaldi Michele (2016). "A Formal definition of Big Data based on its essential features", in *Library Review*, vol. 65, n. 3, 2016, pp. 122-135.

- Dogru Tarik and Osman Pekin (2017). "What do guests' value most in Airbnb accommodations? An application of the hedonic pricing approach".
- Dolnicar S. and Zare S. (2020). "COVID19 and Airbnb—Disrupting the disruptor", in *Annals of Tourism Research*, 102961.
- Duncan Peter, Karen Barton and McKellar Patricia (2001). "Reach and Rich: the new economies of information and the provision of on-line legal services in the U.K." in 16th Bileta Annual Conference.
- Fernández-Macías Enrique - Eurofound (2018), "Automation, digitisation and platforms: Implications for work and employment", Publications Office of the European Union, Luxembourg.
- Edelman Benjamin, Luca Michael and Svirsky Dan (2017). "Racial Discrimination in the Sharing Economy: Evidence from a Field Experiment", in *American Economic Journal: Applied Economics*.
- Eisenmann Thomas R. (2006). "Winner-Take-All in Networked Markets." in *Harvard Business School Background Note 806-131*.
- Evans David S. (2011). "Platform economics: Essays on Multi-Sided Businesses", *Competition Policy International (CPI)*.
- Evans Philip B. and Thomas S. Wurster (1997). "Strategy and the new economics of information.", in *Harvard Business Review*, vol. 75, no. 5.
- Evans Philip B. and Thomas S. Wurster (2000). "Blown to Bits", in *Harvard Business School Press*.
- Fama E. F., Fisher L., Jensen M. C. and Roll R. (1969). "The adjustment of stock prices to new information.", in *International Economic Review*, pp. 1–21.
- Felländer A., Ingram C. and Teigland, R. (2015). "Sharing Econom: Embracing Change with caution".
- Gibbs Chris, Guttentag Daniel, Gretzel Ulrike, Yao Lan and Morton Jym (2018) "Use of dynamic pricing strategies by Airbnb hosts", in *International Journal of Contemporary Hospitality Management*, Vol. 30.

- Gibbs Chris, Guttentag Daniel, Gretzel Ulrike, Morton Jym and Goodwill Alasdair (2018) “Pricing in the sharing economy: a hedonic pricing model applied to Airbnb listings”, *Journal of Travel & Tourism Marketing*, pp.46-56.
- Graef Inge (2019). “Rethinking the essential facilities doctrine for the EU digital economy”, *TILEC Discussion Paper*.
- Gainsforth Sarah (2019). “Airbnb città merce. Storie di resistenza alla gentrificazione digitale”.
- Gutierrez Javier, García-Palomares Juan Carlos, Romanillos Gustavo and Salas-Olmedo María Henar (2017). “The eruption of Airbnb in tourist cities: Comparing spatial patterns of hotels and peer-to-peer accommodation in Barcelona”, in *Tourism Management*, pp. 278-291.
- Guttentag D. (2013). “Airbnb: disruptive innovation and the rise of an informal tourism accommodation sector”, in *Current Issues in Tourism*, pp. 1-26.
- Guttentag D. and Smith S. L. J. (2017). “Assessing Airbnb as a disruptive innovation relative to hotels: Substitution and comparative performance expectations”, in *International Journal of Hospitality Management*.
- Hardy A. and Dolnicar, S. (2017). “Types of network members”, in S. Dolnicar, *Peer-to-Peer Accommodation Networks: Pushing the boundaries*, Oxford: Goodfellow, pp. 170–181.
- Hill Dan (2015). “How much is your spare room worth?”, in *IEEE Spectrum*, vol. 52, no. 9, pp. 32-58.
- Holler J. (2014). “Event Study-Methodik und statistische Signifikanz”.
- Huotari Pontus (2017). “Too Big to Fail? Overcrowding a Multi-Sided Platform and Sustained Competitive Advantage”, in “The Hawaii International Conference on System Sciences”.
- Information Commissioner’s office (2017). “Big data, artificial intelligence, machine learning and data protection”.
- Ismail S., Malone M., van Geest Y. and Diamandis P. (2014). “Exponential Organizations: Why New Organizations are Ten Times Better, Faster and Cheaper than Yours (and What to Do About It)”, in *Diversio Books*.

- Koen Frenken and Juliet Schor (2019). "Putting the sharing economy into perspective".
- Lee C.K. and Taylor T. (2005). "Critical reflections on the economic impact assessment of a mega-event: the case of 2002 FIFA World Cup.", in *Tourism Management* 26, pp.595–603.
- Matheson V.A. (2006). "Mega-Events: The effect of the world's biggest sporting events on local, regional, and national economies" in *Economic Working Paper* 0610.
- Oliveira, Lohmann and Gondim Costa (2016). "Network concentration and airport congestion in a post de-regulation context: A case study of Brazil 2000–2010" in *Journal of Transport Geography*.
- Oskam Jeroen and Boswijk Albert (2016). "Airbnb: the future of networked hospitality businesses", in *Journal of Tourism Futures*, vol. 2, pp. 22-42.
- Roberts K. (2004). "The Business of Leisure: Tourism, Sport, Events and Other Leisure Industries".
- Roche M. (2003). "Mega-events, Time and Modernity: On Time Structures in Global Society".
- Rochet Jean-Charles and Tirole Jean (2003). "Platform competition in Two-Sided Markets", in *Journal of European Economics Association*.
- Shapiro Carl (1999). "Information rules: a strategic guide to the network economy", in *Harvard Business Press*.
- Stock, J. and Watson M. (2011). "Introduction to Econometrics" (3rd ed.), Boston: Addison Wesley.
- Sun Mingchun and Tse Edison (2007). "When Does the Winner Take All in Two-Sided Markets?", in *Review of Network Economics*, Vol.6, Issue 1.
- Wirtz J., So K.K.F., Mody M.A., Liu S.Q. and Chun H.H (2019). "Platforms in the peer-to-peer sharing economy", in *Journal of Service Management*, Vol. 30 No. 4, pp. 452-483.
- Zervas Georgios, Proserpio Davide and Byers W. John (2017). "The Rise of the Sharing Economy: Estimating the Impact of Airbnb on the Hotel Industry", in *Journal of Marketing Research*, pp. 687-705.

Zhu Whang (2016). “Price cap regulation in a two-sided market: Intended and unintended consequences”, in *International Journal of Industrial Organization*, pp. 28-37.

## SITOGRAFIA

<https://en.wikipedia.org/wiki/Airbnb>

<https://news.airbnb.com/it/fast-facts/>

<https://marketingtorino.it/la-storia-di-airbnb-la-community-online-per-chi-viaggia-e-chi-affitta-spazi-abitativi/>

<https://press.airbnb.com/it/about-us/>

<https://www.airbnb.it/help/topic/1355/prezzi-e-costi>

<https://www.airbnb.it/help/article/125/come-viene-determinato-il-prezzo-della-mia-prenotazione>

[https://en.wikipedia.org/wiki/Shock\\_\(economics\)](https://en.wikipedia.org/wiki/Shock_(economics))

[https://it.wikipedia.org/wiki/Web\\_scraping](https://it.wikipedia.org/wiki/Web_scraping)

<https://it.wikipedia.org/wiki/Dataset>

<https://www.milanofinanza.it/news/i-coefficienti-alpha-e-beta-201007281039564639>

# Capitolo 6

## ALLEGATI

### 6.1 Daily Dataset - Caratteristiche

Campo	Descrizione
<i>Property ID</i>	Elemento univoco che caratterizza ogni singolo alloggio
<i>Date</i>	Giorno analizzato da AirDNA
<i>Status</i>	Disponibile (A), Bloccato (B), Prenotato (R)
<i>Booked Date</i>	Giorno della prenotazione da parte del guest
<i>Price (USD)</i>	Prezzo in dollari
<i>Price (Native)</i>	Prezzo in valuta locale
<i>Reservation ID</i>	Elemento univoco che caratterizza la singola prenotazione

### 6.2 Monthly Dataset - Caratteristiche

Campo	Descrizione
<i>Property ID</i>	Elemento univoco che caratterizza ogni singolo alloggio
<i>Host ID</i>	Elemento univoco che caratterizza ogni singolo host
<i>Listing Title</i>	Titolo dell'annuncio
<i>Property Type</i>	Tipologia di alloggio
<i>Listing Type</i>	Tipologia di annuncio: Entire home/apt, Private Room e Shared Room.
<i>Bedrooms</i>	Numero di stanze da letto
<i>Reporting month</i>	Indica il mese per cui è calcolata la performance
<i>Country</i>	Stato
<i>State</i>	Regione
<i>City</i>	Città
<i>ZipCode</i>	Codice postale
<i>Neighborhood</i>	Distretto o quartiere
<i>Metropolitan Statistical Area</i>	/
<i>Occupancy Rate LTM</i>	Rapporto tra giorni prenotati e giorni totali
<i>Revenue (USD)</i>	Ricavo in dollari
<i>Revenue (Native)</i>	Ricavo in valuta locale
<i>Average Daily Rate (USD)</i>	Rapporto tra totale ricavi in dollari su notti prenotate
<i>Average Daily Rate (Native)</i>	Rapporto tra totale ricavi in valuta locale su notti prenotate
<i>Number of Reservation</i>	Numero di prenotazioni
<i>Reservation Days</i>	Numero di giorni prenotati della proprietà
<i>Available Days</i>	Numero di giorni disponibili della proprietà

<i>Blocked Days</i>	Numero di giorni bloccati della proprietà
<i>Latitude</i>	Latitudine
<i>Longitude</i>	Longitudine
<i>Active</i>	Minimo tempo di soggiorno
<i>Scraped during Month</i>	Numero di giorni riservati negli ultimi 12 mesi
<i>Currency Native</i>	Valuta scelta dall'host per l'affitto del proprio alloggio

### 6.3 Annual Properties Performance Dataset - Caratteristiche

<b>Campo</b>	<b>Descrizione</b>
<i>Property ID</i>	Elemento univoco che caratterizza ogni singolo alloggio
<i>Host ID</i>	Elemento univoco che caratterizza ogni singolo host
<i>Listing Title</i>	Titolo dell'annuncio
<i>Property Type</i>	Tipologia di alloggio
<i>Listing Type</i>	Tipologia di annuncio: Entire home/apt, Private Room e Shared Room.
<i>Created Date</i>	Data della creazione dell'annuncio su Airbnb
<i>Last Scraped Date</i>	Ultima data di rilevazione effettuata da AirDNA
<i>Country</i>	Stato
<i>State</i>	Regione
<i>City</i>	Città
<i>ZipCode</i>	Codice postale
<i>Neighborhood</i>	Distretto o quartiere
<i>Metropolitan Statistical Area</i>	/
<i>Currency Native</i>	Valuta scelta dall'host per l'affitto del proprio alloggio
<i>Average Daily Rate (USD)</i>	Rapporto tra totale ricavi in dollari su notti prenotate
<i>Average Daily Rate (Native)</i>	Rapporto tra totale ricavi in valuta locale su notti prenotate
<i>Annual Revenue LTM (USD)</i>	Ricavi annuali in dollari
<i>Annual Revenue LTM (Native)</i>	Ricavi annuali in valuta locale
<i>Occupancy Rate LTM</i>	Rapporto tra giorni prenotati e giorni totali
<i>Number of Bookings LTM</i>	Numero di prenotazioni annuale
<i>Number of Reviews</i>	Numero di recensioni annuali
<i>Bedrooms</i>	Numero di stanze da letto
<i>Bathrooms</i>	Numero di bagni
<i>Max Guests</i>	Numero massimo di ospiti
<i>Calendar Last Updated</i>	L'ultimo aggiornamento del calendario da parte dell'host
<i>Response Rate</i>	Tasso di risposta dell'host
<i>Response Time (min)</i>	Tempo di risposta dell'host
<i>Superhost</i>	Variabile booleana che indica la presenza di un superhost
<i>Cancellation Policy</i>	Modalità di cancellazione della prenotazione
<i>Security Deposit (USD)</i>	Deposito cauzionale richiesto dall'host in dollari
<i>Security Deposit (Native)</i>	Deposito cauzionale richiesto dall'host in valuta locale
<i>Cleaning Fee (USD)</i>	Costo per la pulizia finale richiesta dall'host in dollari
<i>Cleaning Fee (Native)</i>	Costo per la pulizia finale richiesta dall'host in valuta locale
<i>Extra People Fee (USD)</i>	Costo per l'aggiunta di un ospite all'importo originario in dollari
<i>Extra People Fee (Native)</i>	Costo per l'aggiunta di un ospite all'importo originario in valuta locale
<i>Published Nightly Rate (USD)</i>	Prezzo di Airbnb per il pernottamento
<i>Published Monthly Rate (USD)</i>	Prezzo di Airbnb per l'affitto mensile
<i>Published Weekly Rate (USD)</i>	Prezzo di Airbnb per la quota settimanale

<i>Check-In Time</i>	Orario di check-in
<i>Check-out Time</i>	Orario di check-out
<i>Minimum Stay</i>	Minimo tempo di soggiorno
<i>Count Reservation Days LTM</i>	Numero di giorni riservati negli ultimi 12 mesi
<i>Count Available Days LTM</i>	Numero di giorni disponibili negli ultimi 12 mesi
<i>Count Blocked Days LTM</i>	Numero di giorni non disponibili negli ultimi 12 mesi
<i>Number of Photos</i>	Numero delle foto nell'annuncio
<i>Business Ready</i>	Variabile booleana che indica l'esistenza di servizi business
<i>Instantbook Enabled</i>	Variabile booleana che indica l'esistenza della prenotazione istantanea
<i>Listing URL</i>	Indirizzo web dell'annuncio
<i>Listing Main Image URL</i>	Indirizzo web della foto principale dell'annuncio
<i>Latitude</i>	Latitudine dell'alloggio
<i>Longitude</i>	Longitudine dell'alloggio
<i>Overall Rating</i>	Rating dell'alloggio

## 6.4 Codici Python

### 6.4.1 Codice Estrazione Monthly

```
import pandas as pd

percorso_ingresso_file = 'D:\Giuseppe\CONTINENT_europe-continent_Monthly_Match_2020-01-23.csv'

counter = 1
for chunk in pd.read_csv(percorso_ingresso_file, usecols=['Property ID', 'Property Type', 'Listing Type',
                                                         "Bedrooms", "Reporting Month", "Revenue (USD)",
                                                         "Number of Reservations", "Reservation Days", "Available Days",
                                                         "Blocked Days", "Country", "State", "City",
                                                         "Latitude", "Longitude", "Airbnb Host ID"],
                           chunksize=10**7):

    chunkFiltrato = chunk[(chunk['City']=='Saint Petersburg') & (chunk['Property ID'].str.contains("ab"))]
    if counter == 1:
        chunkFiltrato.to_csv('Estrazione_SanPietroburgo_Monthly.csv', index=False)
        counter=0
    else:
        chunkFiltrato.to_csv('Estrazione_SanPietroburgo_Monthly.csv', mode='a', index=False, header=False)
```

### 6.4.2 Codice Estrazione e pulizia Daily Dataset

```
import numpy as np
import sys
print('Librerie importate')
print(' ')

# grandezza del chunk da leggere
chunksize = 10**6
chunk_counter = 1

# percorso di ingresso del daily
import_path_daily = 'D:\Giuseppe\CONTINENT_europe-continent_Daily_Match_2020-01-23.csv'

# percorso in uscita
# non mettere il nome della città perchè lo concateni dopo
export_wip = "D:\Giuseppe\Estrazioni\Daily_Estr"

# percorso in ingresso del property
# serve per avere la città del listing
# poi carico subito il property
import_path_property = "D:\Giuseppe\CONTINENT_europe-continent_Property_Match_2020-02-05.csv"
dfProperty = pd.read_csv(import_path_property, usecols=['Property ID', 'Country', 'City', 'Airbnb Host ID'])
dfProperty = dfProperty[dfProperty['Country']=='Russia']

print('Preparazione fatta.')

# FINE PARTE 1 #####
```

```

# INIZIO PARTE 2 #####

# itera in una lista di città
for country in ['Russia']:
    print('INIZIO: '+country)
    counter = 1
    dfPropertyCity = dfProperty[dfProperty['Country']==country]
    # creo il percorso finale definitivo
    export_path = export_wip+country+'.csv'
    # itero nei vari chunk
    for chunk in pd.read_csv(import_path_daily,usecols=['Property ID','Date','Status','Booked Date','Price (USD)'],
                            chunksize=chunksize):

        # filtro data
        chunk = chunk[(chunk['Date']>='2017-01-01') & (chunk['Date']<='2018-12-31')]

        # Join per la città
        chunk = pd.merge(chunk,dfPropertyCity,how='left',left_on='Property ID',right_on='Property ID')

        # filtro per city
        chunk = chunk[chunk['Country']==country]

        if counter == 1:
            chunk.to_csv(export_path,index=False)
        else:
            chunk.to_csv(export_path,index=False,mode='a',header=False)

        counter += 1
        string='Chunk ... ' + str(counter) + ' \r'
        sys.stdout.write(string)
        sys.stdout.flush()
    print('\nFINITO: '+country)
    print(' ')
print('ESTRAZIONE FATTA.')
```

```

# FINE PARTE 2 #####

df = pd.read_csv("D:\Giuseppe\Estrazioni\Daily_Estr\Daily_EstrSaint Petersburg.csv")

def available(s):
    status = s['Status']
    if status == 'A':
        return 1
    else:
        return 0

def reserved(s):
    status = s['Status']
    if status == 'R':
        return 1
    else:
        return 0

def blocked(s):
    status = s['Status']
    if status == 'B':
        return 1
    else:
        return 0

df['Available'] = df.apply(available,axis=1)
df['Reserved'] = df.apply(reserved,axis=1)
df['Blocked'] = df.apply(blocked,axis=1)

df['Revenue (USD)'] = df['Price (USD)']*df['Reserved']

df = df.groupby("Date").agg({"Revenue (USD)" : "sum", "Reserved" : "sum", "Blocked" : "sum","Available" : "sum",
                            "Price (USD)" : "mean", "Property ID" : pd.Series.nunique, "Airbnb Host ID" : pd.Series.nunique})

df['Occupancy Rate'] = df['Reserved']/(df['Available']+df['Reserved'])
df['Average Daily Rate'] = df['Revenue (USD)']/df['Reserved']
df["City"] = "Saint Petersburg"
df.to_excel(r'D:\Giuseppe\Estrazioni\Event Study\Saint Petersburg_Daily_Agregato.xls', index = False)

df1 = df[['Occupancy Rate','Average Daily Rate']]
df1.reset_index(inplace = True)
df2 = df1.rename(columns={"Date": "date"})
df2.to_csv(r'D:\Giuseppe\Estrazioni\Event Study\Saint Petersburg_Occupancy_Rate.csv', index = False)

```

### 6.4.3 Analisi Descrittiva

```
import numpy as np
import pandas as pd
#apertura dataset San Pietroburgo
df = pd.read_csv("D:\Giuseppe\Estrazioni\Monthly_Estr\Estrazione_SanPietroburgo_Monthly.csv")
#eliminare tutti i NaN così da ripulire il database
df = df.dropna()
print (df)
#filtrare per gli anni considerati
df2 = df.loc[(df["Reporting Month"].str.contains("2017")) |
             (df["Reporting Month"].str.contains("2018")) |
             (df["Reporting Month"].str.contains("2019"))]
#raggruppare i dati per i mesi degli anni considerati
df3 = df2.groupby("Reporting Month").agg({"Revenue (USD)" : "sum", "Number of Reservations" : "sum",
                                         "Reservation Days" : "sum","Available Days" : "sum",
                                         "Property ID" : pd.Series.nunique,
                                         "Airbnb Host ID" : pd.Series.nunique})

#reset index
df3.reset_index(inplace = True)
#variazioni di nuove proprietà
df3 ["New_Airbnb"] = df3["Property ID"] - df3["Property ID"].shift(1)
df3 ["New_Airbnb"] = df3 ["New_Airbnb"].fillna(0)
df3 ["New_Airbnb"] = df3 ["New_Airbnb"].astype(int)
#average revenue monthly
df3 ["Average Revenue (Rev/Res)"] = df3["Revenue (USD)"] / df3["Reservation Days"]

#Aggiunta riga - Valori complessivi per Revenue , Number of Reservations e Reservation Days
df3.loc['Total'] = df3[["Revenue (USD)", "Number of Reservations", "Reservation Days"]].sum()
#Aggiunta riga - Annunci unici
Conta = df.groupby('Property ID').count()
Conta1 = Conta.shape[0]
new_row = pd.Series(data={"Property ID": Conta1}, name='Unique Property')
df3 = df3.append(new_row, ignore_index=False)
#Pulizia finale del nuovo dataset
df3 = df3.replace(np.nan, "0")
print (df3)

#Grafico - Andamento Ricavi mensili

import seaborn as sns
import matplotlib.pyplot as plt

plt.figure(figsize = (50,20))
sns.barplot (data = df3, x = "Reporting Month", y = "Revenue (USD)")
plt.savefig("SanPietroburgo_Revenue.png", bbox_inches = "tight")

#Grafico - Andamento dei ricavi e occupation rate

plt.rcParams["figure.figsize"] = [100,20]

fig, ax1 = plt.subplots()

ax2 = ax1.twinx()
ax2.plot(df3["Reporting Month"], df3["Revenue (USD)"])
ax1.plot(df3["Reporting Month"], df3["Occupation Rate"], 'o-', color="red" )

ax1.axhline(0)

ax3 = plt.subplot(122)
ax4 = ax3.twinx()

ax3.plot(df3["Reporting Month"], df3["Revenue (USD)"],c='r')
ax4.plot(df3["Reporting Month"], df3["Occupation Rate"],c='b')

ax3.axhline(0)

ax3.set_ylim(0,75100000)
ax4.set_ylim(0,1)

NA = mpatches.Patch(color='red', label='Revenue (USD)')
SA = mpatches.Patch(color='blue', label='Occupation Rate')
plt.legend(handles=[NA,SA], loc=2,prop={'size': 20})

plt.savefig("SanPietroburgo_REV_OCC.png", bbox_inches = "tight")

plt.show()
```

```

#Grafico - Andamento dei nuovi e totali annunci
plt.rcParams["figure.figsize"] = [100,20]

fig, ax1 = plt.subplots()

ax2 = ax1.twinx()
ax2.plot(df3["Reporting Month"], df3["New_Airbnb"])
ax1.plot(df3["Reporting Month"], df3["Property ID"], 'o-', color="red" )

ax1.axhline(0)

ax3 = plt.subplot(122)
ax4 = ax3.twinx()

ax3.plot(df3["Reporting Month"], df3["New_Airbnb"],c='r')
ax4.plot(df3["Reporting Month"], df3["Property ID"],c='b')

ax3.axhline(0)

ax3.set_ylim(-5000,190000)
ax4.set_ylim(-5000,190000)

NA = mpatches.Patch(color='red', label='New Airbnb')
SA = mpatches.Patch(color='blue', label='TOT Airbnb')
plt.legend(handles=[NA,SA], loc=2,prop={'size': 20})

plt.savefig("SanPietroburgo_New-TOT.png", bbox_inches = "tight")
plt.show()

#Grafico - Andamento del numero di prenotazioni

import seaborn as sns
import matplotlib.pyplot as plt

plt.figure(figsize = (50,20))
sns.lineplot (data = df3, x = "Reporting Month", y = "Number of Reservations")

SA = mpatches.Patch(color='blue', label='Number of Reservations')
plt.legend(handles=[SA], loc=2,prop={'size': 20})
plt.savefig("SanPietroburgo_Reservation.png", bbox_inches = "tight")

#filtrare per l'anno considerato 2017
df4 = df.loc[(df["Reporting Month"].str.contains("2017"))]
#filtrare per Property ID aggregandole
df322 = df4.groupby('Property ID').agg({"Listing Type" : "first", "Revenue (USD)": "sum",
                                       "Available Days": "sum", "Reservation Days": "sum",
                                       'Number of Reservations': "sum"}).reset_index()

#contare le Property Type
counts = df322["Listing Type"].value_counts().to_frame('anno2017')
av_redays = df322.groupby('Listing Type').agg({"Revenue (USD)": "sum", "Available Days": "sum",
                                             "Reservation Days": "sum", 'Number of Reservations': "sum"})

#filtrare per l'anno considerato 2018
df5 = df.loc[(df["Reporting Month"].str.contains("2018"))]
#filtrare per Property ID aggregandole
df10 = df5.groupby('Property ID').agg({"Listing Type" : "first", "Revenue (USD)": "sum",
                                       "Available Days": "sum", "Reservation Days": "sum",
                                       'Number of Reservations': "sum"}).reset_index()

#contare le Property Type
counts1 = df10["Listing Type"].value_counts().to_frame('anno2018')
av_redays1 = df10.groupby('Listing Type').agg({"Revenue (USD)": "sum", "Available Days": "sum",
                                             "Reservation Days": "sum", 'Number of Reservations': "sum"})

#filtrare per l'anno considerato 2019
df6 = df.loc[(df["Reporting Month"].str.contains("2019"))]
#filtrare per Property ID aggregandole
df11 = df6.groupby('Property ID').agg({"Listing Type" : "first", "Revenue (USD)": "sum",
                                       "Available Days": "sum", "Reservation Days": "sum",
                                       'Number of Reservations': "sum"}).reset_index()

#contare le Property Type
counts2 = df11["Listing Type"].value_counts().to_frame('anno2019')
av_redays2 = df11.groupby('Listing Type').agg({"Revenue (USD)": "sum", "Available Days": "sum",
                                             "Reservation Days": "sum", 'Number of Reservations': "sum"})

#Unico dataframe con i counts per sapere il numero di Listing Type per anno
counts ["anno2018"] = counts1
counts ["anno2019"] = counts2

#Studiare percentuali Listing type per anno
counts['% 2017'] = (counts.anno2017 * 100 / counts.anno2017.sum()).round(1).astype(str) + '%'
counts['% 2018'] = (counts.anno2018 * 100 / counts.anno2018.sum()).round(1).astype(str) + '%'
counts['% 2019'] = (counts.anno2019 * 100 / counts.anno2019.sum()).round(1).astype(str) + '%'
counts.loc['Total'] = counts[['anno2017', 'anno2018', 'anno2019']].sum()

#Concatenare Listing type in funzione dei diversi parametri
frames = [av_redays, av_redays1, av_redays2]
Av_Redays = pd.concat(frames, axis=1, sort=False)

```

```

Av_Redays.columns = ["Revenue (USD)_2017", "Available Days_2017", "Reservation Days_2017",
                    "Number of Reservations_2017", "Revenue (USD)_2018", "Available Days_2018",
                    "Reservation Days_2018", "Number of Reservations_2018", "Revenue (USD)_2019",
                    "Available Days_2019", "Reservation Days_2019", "Number of Reservations_2019" ]
Av_Redays.loc['Total'] = Av_Redays[["Revenue (USD)_2017", "Available Days_2017", "Reservation Days_2017",
                                    "Number of Reservations_2017", "Revenue (USD)_2018", "Available Days_2018",
                                    "Reservation Days_2018", "Number of Reservations_2018", "Revenue (USD)_2019",
                                    "Available Days_2019", "Reservation Days_2019", "Number of Reservations_2019" ]].sum()
Av_Redays.loc['Mean'] = Av_Redays[["Revenue (USD)_2017", "Available Days_2017", "Reservation Days_2017",
                                    "Number of Reservations_2017", "Revenue (USD)_2018", "Available Days_2018",
                                    "Reservation Days_2018", "Number of Reservations_2018", "Revenue (USD)_2019",
                                    "Available Days_2019", "Reservation Days_2019", "Number of Reservations_2019" ]].mean()

|
Supply = counts[['anno2017', '% 2017', 'anno2018', '% 2018', 'anno2019', '% 2019']].replace(np.nan, " ")
print(Av_Redays)
print(Supply)

writer = pd.ExcelWriter('SanPietroburgo_STAT.xlsx', engine='xlsxwriter')

df3.to_excel(writer, sheet_name='Table MON')
Supply.to_excel(writer, sheet_name='Table LISTED Property')
Av_Redays.to_excel(writer, sheet_name='Table APP Property')

writer.save()

```

## 6.4.4 Regressione lineare

```

import numpy as np
import pandas as pd
import seaborn as sns
from scipy import stats
import matplotlib.pyplot as plt
import seaborn as sns
import statsmodels.api as sm
from statsmodels.stats import diagnostic as diag
from statsmodels.stats.outliers_influence import variance_inflation_factor
import matplotlib.pyplot as plt
import matplotlib.patches as mpatches
from sklearn.linear_model import LinearRegression
from sklearn.model_selection import train_test_split
from sklearn.metrics import mean_squared_error, r2_score, mean_absolute_error

#apertura del df
df = pd.read_excel(r'/Users/giuseppevitulano/Desktop/Milone/3 MODELLO/Saint Petersburg_12mesi.xls')
#scelta periodo in esame
df1 = df.loc[(df['Date'] >= '2017-01-01') & (df['Date'] <= '2018-07-22')]
econ_df = df1.set_index('Date')
print(econ_df)

#definizione della variabile dipendente
X = econ_df.drop('Average Daily Revenue', axis = 1)
#definizione dell* variabil* indipendent*
Y = econ_df[['Average Daily Revenue']]

# Fase di training e test
X_train, X_test, y_train, y_test = train_test_split(X, Y, train_size=0.962, shuffle=False)

# Linear Regression model
regression_model = LinearRegression()

# Stima sulla fase di training
regression_model.fit(X_train, y_train)
X2 = sm.add_constant(X_train)
model = sm.OLS(y_train, X2)
#Newey West
est = model.fit(cov_type='HAC', cov_kwds={'maxlags':6}, use_correction=True, use_t=True)

#Risultati retta di regressione
print(est.summary())

#Stima della variabile dipendente e confronto con i valori effettivi
y_p = regression_model.predict(X_train)
Predizioni_n = Y[["Average Daily Revenue"]]
KAK = Predizioni_n.reset_index()

Predizioni_normali = KAK.loc[(KAK['Date'] >= '2017-01-01') & (KAK['Date'] <= '2017-12-31')]
Predizioni_normali["Predicted"] = y_p

print(Predizioni_normali)

```

```

#Grafico di stima della variabile dipendente e confronto con i valori predetti
plt.rcParams["figure.figsize"] = [60,10]

fig, ax1 = plt.subplots()
Predizioni_normali['Date'] = pd.to_datetime(Predizioni_normali['Date'])
ax2 = ax1.twinx()
ax2.plot(Predizioni_normali["Date"], Predizioni_normali["Average Daily Revenue"])
ax1.plot(Predizioni_normali["Date"], Predizioni_normali["Predicted"], 'o-', color="red" )

ax1.axhline(0)

ax3 = plt.subplot(122)
ax4 = ax3.twinx()

ax3.plot(Predizioni_normali["Date"], Predizioni_normali["Average Daily Revenue"],c='r')
ax4.plot(Predizioni_normali["Date"], Predizioni_normali["Predicted"],c='b')

ax3.axhline(0)

ax3.set_ylim(0,200)
ax4.set_ylim(0,200)

NA = mpatches.Patch(color='red', label='Average Daily Revenue')
SA = mpatches.Patch(color='blue', label='Predicted')
plt.legend(handles=[NA,SA], loc=2,prop={'size': 20})
sns.set_context("talk")

ticklabels = df.Date.dt.strftime('%Y-%m-%d')

ax.xaxis.set_major_formatter(ticker.FixedFormatter(ticklabels))

spacing = 30
visible = ax.xaxis.get_ticklabels()[::spacing]
for label in ax.xaxis.get_ticklabels():
    if label not in visible:
        label.set_visible(False)

plt.show()

# Analisi sui valori predetti (AR,CAR e T-Test)

def OUTPUT(k):
    if k > 1.96 or k < -1.96:
        print('SIGNIFICANT')

y_predic = regression_model.predict(X_test)

df2 = df.loc[(df['Date'] >= '2018-01-01') & (df['Date'] <= '2018-07-22')]
df4 = df2[["Average Daily Revenue"]]
df4["Predicted"] = y_predic
df4["Date"] = df2["Date"]

df5 = df4.loc[(df4['Date'] >= '2018-07-11') & (df4['Date'] <= '2018-07-22')]

df5["AR"] = df5["Average Daily Revenue"] - df5["Predicted"]
df5["CAR"] = df5["AR"] + df5["AR"].shift(1)
df5['STD AR'] = df5['AR'].std()
df5['T-Test AR'] = df5['AR'] / df5['STD AR']

df5["Period"] = [-3,-2,-1,0,1,2,3,4,5,6,7,8]
df5 = df5.set_index('Period')
df5 = df5.fillna(df5.at[-3, 'AR'])
print(df5)
def OUTPUT(k):
    if k > 1.96 or k < -1.96:
        return 'Si'
df5['Significant'] = df5['T-Test AR'].apply(OUTPUT)

#Grafico AR-CAR
plt.rcParams["figure.figsize"] = [60,10]

fig, ax1 = plt.subplots()

```

```

ax2 = ax1.twinx()
ax2.plot(df5.index, df5["AR"])
ax1.plot(df5.index, df5["CAR"], 'o-', color="blue" )

ax1.axhline(0)

ax3 = plt.subplot(122)
ax4 = ax3.twinx()

ax3.plot(df5.index, df5["AR"],c='grey')
ax4.plot(df5.index, df5["CAR"],c='blue')

ax3.axhline(0)
plt.axhline(y=0, color='black', linestyle='-')
plt.axvline(x=0, color='red', linestyle='-')

ax3.set_ylim(-100,+150)
ax4.set_ylim(-100,150)

NA = mpatches.Patch(color='grey', label='AR')
SA = mpatches.Patch(color='blue', label='CAR')
plt.legend(handles=[NA,SA], loc=2,prop={'size': 20})
sns.set_context("talk")

plt.show()

```

## 6.5 Dati descrittivi

### 6.5.1 Russia

RUSSIA									
Reporting Month	Revenue (USD)	Number of Reservations	Reservation Days	Available Days	Property ID	Airbnb Host ID	New Property ID	Average Monthly Revenue	Occupation Rate
2017-01-01	6602097	34097	114305	241071	12775	6789	0	57,76	0,322
2017-02-01	5379220	29806	99890	145951	9936	5140	-2839	53,85	0,406
2017-03-01	5395764	31408	105942	149415	9546	4942	-390	50,93	0,415
2017-04-01	7086761	39962	131566	180905	12117	6252	2571	53,86	0,421
2017-05-01	10906144	54803	185155	257627	16188	8268	4071	58,90	0,418
2017-06-01	15321954	72912	250236	250561	19200	9944	3012	61,23	0,500
2017-07-01	16998877	83555	299660	1053508	53574	27647	34374	56,73	0,221
2017-08-01	16528482	80210	292503	1107143	55223	28476	1649	56,51	0,209
2017-09-01	11143267	64460	218233	1158948	56536	29154	1313	51,06	0,158
2017-10-01	10106745	65153	207987	1207616	57295	29498	759	48,59	0,147
2017-11-01	9174219	62251	190136	1185750	58468	30113	1173	48,25	0,138
2017-12-01	10722159	65357	190708	1292065	61346	31503	2878	56,22	0,129
2018-01-01	13731968	71373	225694	1290901	63147	32622	1801	60,84	0,149
2018-02-01	9825380	59592	182192	1244781	68723	36258	5576	53,93	0,128
2018-03-01	11748010	72800	226261	1470069	76200	41289	7477	51,92	0,133
2018-04-01	13868535	88169	270235	1553383	89017	50139	12817	51,32	0,148
2018-05-01	20435267	97497	326389	1918721	107948	63870	18931	62,61	0,145
2018-06-01	70745579	197650	646212	2696943	141893	87498	33945	109,48	0,193
2018-07-01	51409863	180176	633559	2970706	148719	90804	6826	81,14	0,176
2018-08-01	31674162	162461	594170	2797146	151745	92408	3026	53,31	0,175
2018-09-01	21116702	123185	430101	2888934	154584	94192	2839	49,10	0,130
2018-10-01	18004194	117607	389423	3007772	156434	95374	1850	46,23	0,115
2018-11-01	13255504	102870	295061	2927836	158238	96480	1804	44,92	0,092
2018-12-01	16687681	113725	338410	3074363	160856	97854	2618	49,31	0,099
2019-01-01	19930149	117329	376380	3080627	162948	98829	2092	52,95	0,109
2019-02-01	13575223	95664	297133	2797892	164580	99683	1632	45,69	0,096
2019-03-01	16380647	122251	372462	3078002	166271	100369	1691	43,98	0,108
2019-04-01	18366888	130066	414805	2956380	166917	100504	646	44,28	0,123
2019-05-01	26193036	162665	537228	3042135	168773	101127	1856	48,76	0,150
2019-06-01	32857095	180425	617576	2886995	166184	98844	-2589	53,20	0,176
2019-07-01	40446487	221349	757661	2796429	162137	96018	-4047	53,38	0,213
2019-08-01	47553966	313420	888068	2546226	162159	95791	22	53,55	0,259
2019-09-01	35467961	224232	697877	2293335	162033	95437	-126	50,82	0,233
2019-10-01	19681656	182804	419911	2870142	160140	94375	-1893	46,87	0,128
2019-11-01	24170322	227286	532024	2777510	158131	93074	-2009	45,43	0,161
2019-12-01	31653357	149337	613502	2957747	161277	93792	3146	51,59	0,172

## 6.5.2 Mosca

MOSCA									
Reporting Month	Revenue (USD)	Number of	Reservation Days	Available Days	Property ID	Airbnb Host ID	New Property ID	Average Monthly Revenue	Occupation Rate
2017-01-01	1972256	10002	32321	50640	3075	1439	0	61,02	0,390
2017-02-01	2027709	9469	31425	28065	2528	1175	-547	64,53	0,528
2017-03-01	2100091	10308	33542	32269	2582	1193	54	62,61	0,510
2017-04-01	2588065	11865	39378	34207	2969	1362	387	65,72	0,535
2017-05-01	2833560	12682	42573	43790	3302	1517	333	66,56	0,493
2017-06-01	3288066	15404	50420	41686	3682	1722	380	65,21	0,547
2017-07-01	3545160	16903	57079	234052	12116	6218	8434	62,11	0,196
2017-08-01	3719844	17220	58167	236516	12318	6267	202	63,95	0,197
2017-09-01	3766168	18145	59099	224986	12541	6358	223	63,73	0,208
2017-10-01	4062849	20351	64887	227251	12670	6392	129	62,61	0,222
2017-11-01	3730401	19120	59888	221773	12810	6506	140	62,29	0,213
2017-12-01	4315514	20629	62763	240675	13372	6724	562	68,76	0,207
2018-01-01	4419530	20498	63602	245362	13587	6861	215	69,49	0,206
2018-02-01	3943629	19111	58944	226744	14700	7550	1113	66,90	0,206
2018-03-01	4451502	21174	66227	271810	16314	8678	1614	67,22	0,196
2018-04-01	4954436	23731	75591	288203	19676	11226	3362	65,54	0,208
2018-05-01	5821988	22610	78347	378743	25398	15648	5722	74,31	0,171
2018-06-01	29869199	56073	198072	610963	36876	24311	11478	150,80	0,245
2018-07-01	19676570	46895	163574	745675	38619	25223	1743	120,29	0,180
2018-08-01	8493627	34890	125179	660943	39247	25569	628	67,85	0,159
2018-09-01	7708775	33650	117699	643288	39846	25963	599	65,50	0,155
2018-10-01	7409028	35138	118844	663705	40173	26177	327	62,34	0,152
2018-11-01	5398697	30898	93022	643122	40416	26316	243	58,04	0,126
2018-12-01	6729901	35479	110782	661695	40843	26502	427	60,75	0,143
2019-01-01	6708811	33989	107415	668291	40972	26511	129	62,46	0,138
2019-02-01	5445487	29920	95017	585889	41064	26591	92	57,31	0,140
2019-03-01	6161365	35335	110532	646628	41259	26603	195	55,74	0,146
2019-04-01	6830019	36620	119417	612317	41148	26479	-111	57,19	0,163
2019-05-01	6874412	35832	121685	633811	40767	26198	-381	56,49	0,161
2019-06-01	8115752	39909	135313	585327	39033	24917	-1734	59,98	0,188
2019-07-01	9589121	46365	153644	569878	36942	23363	-2091	62,41	0,212
2019-08-01	10795862	58592	167247	518840	36356	22878	-586	64,55	0,244
2019-09-01	10082352	48751	155321	427723	36023	22514	-333	64,91	0,266
2019-10-01	6643876	47213	110675	532922	35414	22061	-609	60,03	0,172
2019-11-01	8238819	57300	137799	519615	34789	21619	-625	59,79	0,210
2019-12-01	11703290	39754	176999	544210	35275	21509	486	66,12	0,245

Annunci per tipologia	Anno 2017	% 2017	Anno 2018	% 2018	Anno 2019	% 2019
Entire home/apt	10447	69.0%	33908	75.8%	37783	75.0%
Private room	3375	22.3%	8246	18.4%	8951	17.8%
Shared room	1150	7.6%	2181	4.9%	2418	4.8%
Hotel room	176	1.2%	427	1.0%	1237	2.5%
Total	15148		44762		50389	

### 6.5.3 San Pietroburgo

SAN PIETROBURGO									
Reporting Month	Revenue (USD)	Number of Reservations	Reservation Days	Available Days	Property ID	Airbnb Host ID	New Property ID	Average Monthly Revenue	Occupation Rate
2017-01-01	2293643	12679	44921	83853	4779	2438	0	51,06	0,349
2017-02-01	1689155	10696	38179	47648	3580	1740	-1199	44,24	0,445
2017-03-01	1942601	11816	42190	49886	3544	1698	-36	46,04	0,458
2017-04-01	2861740	15926	54981	60905	4669	2247	1125	52,05	0,474
2017-05-01	5553367	25192	88633	97274	6906	3345	2237	62,66	0,477
2017-06-01	8641561	35571	127879	88059	8383	4116	1477	67,58	0,592
2017-07-01	8284945	36560	135766	276734	17142	8303	8759	61,02	0,329
2017-08-01	7216345	32015	121007	303835	17494	8508	352	59,64	0,285
2017-09-01	4068709	23476	83238	320800	17699	8600	205	48,88	0,206
2017-10-01	3519342	23049	78396	324804	17737	8635	38	44,89	0,194
2017-11-01	3019707	20987	69389	316433	17914	8729	177	43,52	0,180
2017-12-01	3165641	20858	65099	346125	18543	9023	629	48,63	0,158
2018-01-01	4040347	22263	76141	339296	18748	9119	205	53,06	0,183
2018-02-01	2596999	17738	59140	315604	19337	9442	589	43,91	0,158
2018-03-01	3383582	22534	75480	351101	20107	9924	770	44,83	0,177
2018-04-01	4580399	29845	95769	348994	21784	10949	1677	47,83	0,215
2018-05-01	7730982	37322	128542	387082	24042	12588	2258	60,14	0,249
2018-06-01	16924691	56636	194161	454475	29144	16168	5102	87,17	0,299
2018-07-01	14147248	58048	208945	497865	30316	16726	1172	67,71	0,296
2018-08-01	10675468	55761	208132	472254	30723	16962	407	51,29	0,306
2018-09-01	6217393	39103	139981	496457	30997	17172	274	44,42	0,220
2018-10-01	5231465	37508	129993	502538	31114	17300	117	40,24	0,206
2018-11-01	3749518	31863	95724	489296	31243	17447	129	39,17	0,164
2018-12-01	4379815	33583	105676	518180	31529	17639	286	41,45	0,169
2019-01-01	5327662	33676	115178	515720	31799	17730	270	46,26	0,183
2019-02-01	3288960	26730	89834	464444	31937	17789	138	36,61	0,162
2019-03-01	4215040	33997	110868	497568	32187	17810	250	38,02	0,182
2019-04-01	5675823	39457	133139	463923	32152	17726	-35	42,63	0,223
2019-05-01	10464577	57228	197912	448731	32778	17915	626	52,87	0,306
2019-06-01	14683742	68111	241541	403223	32883	17849	105	60,79	0,375
2019-07-01	15044059	72256	260976	397047	32704	17625	-179	57,65	0,397
2019-08-01	15555681	88428	275958	369937	32980	17610	276	56,37	0,427
2019-09-01	9432853	60538	199446	383426	33027	17484	47	47,30	0,342
2019-10-01	6298506	54281	142248	442192	32626	17208	-401	44,28	0,243
2019-11-01	6963186	64558	165183	427760	32207	16903	-419	42,15	0,279
2019-12-01	8578306	40428	183688	476517	33139	17106	932	46,70	0,278

Annunci per tipologia	Anno 2017	% 2017	Anno 2018	% 2018	Anno 2019	% 2019
Entire home/apt	14224	70.3%	26598	73.4%	31123	72.4%
Private room	4873	24.1%	7868	21.7%	8964	20.9%
Shared room	886	4.4%	1229	3.4%	1537	3.6%
Hotel room	238	1.2%	540	1.5%	1342	3.1%
Total	20221		36235		42966	

### 6.5.4 Nizhnij Novgorod

NIZHNIJ NOVGOROD									
Reporting Month	Revenue (USD)	Number of Reservations	Reservation Days	Available Days	Property ID	Airbnb Host ID	New Property ID	Average Monthly Revenue	Occupation Rate
2017-01-01	67244	513	1455	4802	212	89	0	46,22	0,233
2017-02-01	49139	442	1158	3431	168	83	-44	42,43	0,252
2017-03-01	39772	424	1075	2432	122	59	-46	37,00	0,307
2017-04-01	61811	653	1523	4243	202	96	80	40,58	0,264
2017-05-01	94053	895	2243	4967	246	110	44	41,93	0,311
2017-06-01	96733	998	2491	4160	248	108	2	38,83	0,375
2017-07-01	171094	1617	3976	10062	518	226	270	43,03	0,283
2017-08-01	135217	1330	3368	11335	539	236	21	40,15	0,229
2017-09-01	91326	991	2394	12197	555	245	16	38,15	0,164
2017-10-01	90671	1083	2596	12531	564	248	9	34,93	0,172
2017-11-01	101092	1172	2730	12631	599	259	35	37,03	0,178
2017-12-01	119581	1123	2863	14369	694	324	95	41,77	0,166
2018-01-01	179796	1330	3470	15738	829	436	135	51,81	0,181
2018-02-01	146140	1026	2704	12304	1580	1058	751	54,05	0,108
2018-03-01	224890	1412	3713	38825	2687	1984	1107	60,57	0,087
2018-04-01	283839	1760	4420	52118	4109	3066	1422	64,22	0,078
2018-05-01	603916	1808	5903	77619	5652	4263	1543	102,31	0,071
2018-06-01	2530671	7315	18146	169588	7684	5715	2032	139,46	0,097
2018-07-01	2219583	6313	18044	177970	7944	5834	260	123,01	0,092
2018-08-01	983177	4267	13377	150511	7987	5858	43	73,50	0,082
2018-09-01	421046	2247	7065	156560	8051	5885	64	59,60	0,043
2018-10-01	315588	2117	6370	162472	8105	5914	54	49,54	0,038
2018-11-01	274135	2029	5167	156217	8148	5936	43	53,05	0,032
2018-12-01	261240	1928	5753	160659	8219	5971	71	45,41	0,035
2019-01-01	310418	2210	6692	159843	8256	5991	37	46,39	0,040
2019-02-01	223725	1690	4541	144986	8286	6000	30	49,27	0,030
2019-03-01	235178	2355	6183	159471	8249	5966	-37	38,04	0,037
2019-04-01	267646	2340	6151	152084	8085	5871	-164	43,51	0,039
2019-05-01	284634	3062	7991	152214	7853	5728	-232	35,62	0,050
2019-06-01	302570	2897	7698	141979	7304	5344	-549	39,30	0,051
2019-07-01	496954	3906	9458	136533	6572	4841	-732	52,54	0,065
2019-08-01	696838	6429	13871	118689	6343	4720	-229	50,24	0,105
2019-09-01	583036	3853	10618	88334	6273	4663	-70	54,91	0,107
2019-10-01	241503	3345	6133	125301	6152	4592	-121	39,38	0,047
2019-11-01	322493	4089	8431	120768	6065	4536	-87	38,25	0,065
2019-12-01	429547	2607	9995	125994	6029	4490	-36	42,98	0,073

Annunci per tipologia	Anno 2017	% 2017	Anno 2018	% 2018	Anno 2019	% 2019
Entire home/apt	598	85.1%	7300	88.7%	7777	88.4%
Private room	80	11.4%	747	9.1%	822	9.3%
Shared room	18	2.6%	165	2.0%	177	2.0%
Hotel room	7	1.0%	14	0.2%	23	0.3%
Total	703		8226		8799	

### 6.5.5 Kazan

KAZAN									
Reporting Month	Revenue (USD)	Number of Reservations	Reservation Days	Available Days	Property ID	Airbnb Host ID	New Property ID	Average Monthly Revenue	Occupation Rate
2017-01-01	183215	1309	3940	9781	466	224	0	46,50	0,287
2017-02-01	94046	1023	2720	5842	324	170	-142	34,58	0,318
2017-03-01	117454	1241	3367	5191	300	153	-24	34,88	0,393
2017-04-01	163590	1660	4175	7796	428	224	128	39,18	0,349
2017-05-01	321176	2543	7130	12718	676	324	248	45,05	0,359
2017-06-01	464727	3345	9411	11199	752	394	76	49,38	0,457
2017-07-01	435990	3755	10502	19882	1124	575	372	41,51	0,346
2017-08-01	483182	3793	11192	20121	1178	599	54	43,17	0,357
2017-09-01	231106	2373	6371	25244	1243	626	65	36,27	0,202
2017-10-01	250293	2646	6897	26441	1280	642	37	36,29	0,207
2017-11-01	291387	2880	7355	25519	1339	676	59	39,62	0,224
2017-12-01	286451	2674	6462	30978	1489	738	150	44,33	0,173
2018-01-01	557151	3435	9864	29136	1591	805	102	56,48	0,253
2018-02-01	258945	2410	6418	34146	1937	1028	346	40,35	0,158
2018-03-01	426435	3759	9823	45991	2597	1449	660	43,41	0,176
2018-04-01	587533	4699	12466	59665	3858	2315	1261	47,13	0,173
2018-05-01	973587	5488	16018	94905	5854	3768	1996	60,78	0,144
2018-06-01	4573799	14455	39733	177319	8788	5822	2934	115,11	0,183
2018-07-01	2441100	11175	32388	199981	9254	6047	466	75,37	0,139
2018-08-01	1455193	10612	32787	177896	9413	6129	159	44,38	0,156
2018-09-01	708082	5604	16673	187464	9591	6193	178	42,47	0,082
2018-10-01	657301	5487	15846	193086	9746	6249	155	41,48	0,076
2018-11-01	537994	5310	12731	186987	9975	6361	229	42,26	0,064
2018-12-01	632830	5240	14011	197273	10248	6506	273	45,17	0,066
2019-01-01	953063	6227	19290	196263	10536	6666	288	49,41	0,089
2019-02-01	422644	4282	11274	184711	10739	6762	203	37,49	0,058
2019-03-01	693388	6690	18207	202550	10943	6867	204	38,08	0,082
2019-04-01	639351	6576	18834	197478	11004	6877	61	33,95	0,087
2019-05-01	1283157	9165	27842	196768	11019	6889	15	46,09	0,124
2019-06-01	923545	7512	22643	188501	10572	6587	-447	40,79	0,107
2019-07-01	1273248	10144	29956	177377	10033	6282	-539	42,50	0,144
2019-08-01	1847255	14628	38314	154631	9764	6136	-269	48,21	0,199
2019-09-01	1129985	8696	25149	139068	9655	6107	-109	44,93	0,153
2019-10-01	597348	7607	16094	165040	9276	5958	-379	37,12	0,089
2019-11-01	755756	8370	18938	157551	9060	5823	-216	39,91	0,107
2019-12-01	928897	6036	22057	165471	9057	5828	-3	42,11	0,118

Annunci per tipologia	Anno 2017	% 2017	Anno 2018	% 2018	Anno 2019	% 2019
Entire home/apt	1320	87.7%	9288	90.5%	11387	89.1%
Private room	124	8.2%	674	6.6%	894	7.0%
Shared room	41	2.7%	264	2.6%	415	3.2%
Hotel room	20	1.3%	41	0.4%	82	0.6%
Total	1505		10267		12778	

## 6.5.6 Samara

SAMARA									
Reporting Month	Revenue (USD)	Number of Reservations	Reservation Days	Available Days	Property ID	Airbnb Host ID	New Property ID	Average Monthly Revenue	Occupation Rate
2017-01-01	20873	197	562	1815	84	43	0	37,14	0,236
2017-02-01	32688	199	681	1210	76	45	-8	48,00	0,360
2017-03-01	26037	181	627	1784	85	47	9	41,53	0,260
2017-04-01	21267	151	542	1682	79	50	-6	39,24	0,244
2017-05-01	27151	174	651	1751	84	62	5	41,71	0,271
2017-06-01	37838	278	956	2036	111	73	27	39,58	0,320
2017-07-01	41688	356	1184	14928	603	308	492	35,21	0,073
2017-08-01	49945	367	1291	15475	626	323	23	38,69	0,077
2017-09-01	40240	307	974	16545	674	346	48	41,31	0,056
2017-10-01	44090	339	1116	17451	700	362	26	39,51	0,060
2017-11-01	49204	384	1040	16895	720	373	20	47,31	0,058
2017-12-01	43829	346	915	18368	755	400	35	47,90	0,047
2018-01-01	44178	333	1023	18842	800	434	45	43,18	0,051
2018-02-01	47933	315	886	20915	1112	668	312	54,10	0,041
2018-03-01	105797	440	1282	32130	1675	1068	563	82,53	0,038
2018-04-01	133340	529	1622	47191	2795	1885	1120	82,21	0,033
2018-05-01	350257	888	2979	72060	4202	2970	1407	117,58	0,040
2018-06-01	2253605	6284	16655	134686	6109	4356	1907	135,31	0,110
2018-07-01	1735361	5102	14619	154171	6638	4598	529	118,71	0,087
2018-08-01	558994	1666	6392	143907	6719	4621	81	87,45	0,043
2018-09-01	232267	1151	3741	145350	6778	4654	59	62,09	0,025
2018-10-01	202042	1185	3545	149463	6821	4679	43	56,99	0,023
2018-11-01	138500	972	2837	141143	6791	4680	-30	48,82	0,020
2018-12-01	148121	1072	3030	144361	6798	4690	7	48,88	0,021
2019-01-01	117376	1000	2977	142954	6787	4680	-11	39,43	0,020
2019-02-01	109866	991	2765	128044	6771	4674	-16	39,73	0,021
2019-03-01	108924	1065	2829	140032	6696	4648	-75	38,50	0,020
2019-04-01	106376	929	2607	134412	6646	4626	-50	40,80	0,019
2019-05-01	140703	1432	4086	134637	6495	4541	-151	34,44	0,029
2019-06-01	192537	1429	4426	123205	6054	4265	-441	43,50	0,035
2019-07-01	311930	2098	5918	116374	5354	3836	-700	52,71	0,048
2019-08-01	420718	3658	7711	104264	5144	3727	-210	54,56	0,069
2019-09-01	415806	2591	6797	78125	5060	3689	-84	61,17	0,080
2019-10-01	149047	1724	3090	108243	4987	3634	-73	48,24	0,028
2019-11-01	180482	2225	4267	103960	4866	3561	-121	42,30	0,039
2019-12-01	223724	1412	5385	105050	4808	3540	-58	41,55	0,049

Annunci per tipologia	Anno 2017	% 2017	Anno 2018	% 2018	Anno 2019	% 2019
Entire home/apt	716	87.7%	6439	90.2%	6536	89.6%
Private room	74	9.1%	584	8.2%	657	9.0%
Shared room	24	2.9%	107	1.5%	97	1.3%
Hotel room	2	0.2%	5	0.1%	7	0.1%
Total	816		7135		7297	

### 6.5.7 Sochi

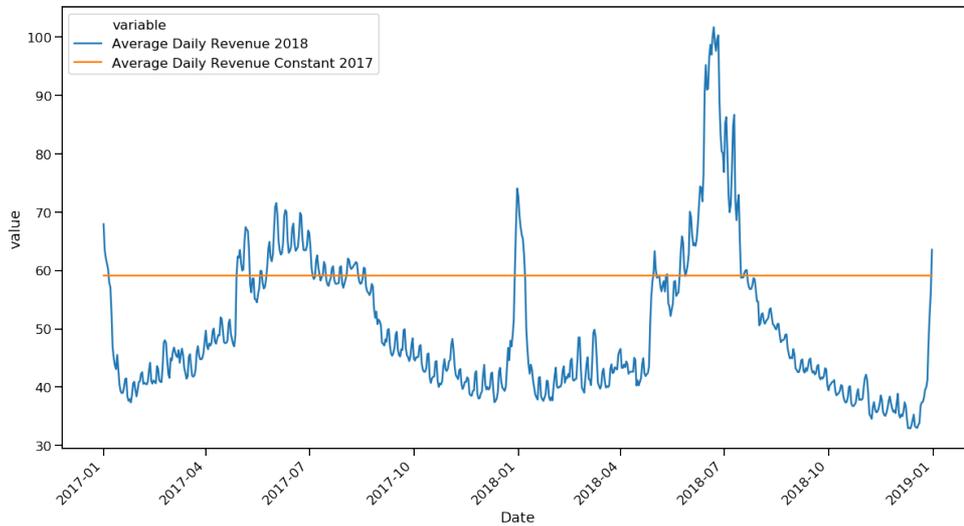
SOCHI									
Reporting Month	Revenue (USD)	Number of Reservations	Reservation Days	Available Days	Property ID	Airbnb Host ID	New Property ID	Average Monthly Revenue	Occupation Rate
2017-01-01	105034	508	1946	4530	230	166	0	53,97	0,300
2017-02-01	62684	377	1378	1905	134	88	-96	45,49	0,420
2017-03-01	100206	497	2073	2630	177	118	43	48,34	0,441
2017-04-01	130099	571	2492	3062	222	151	45	52,21	0,449
2017-05-01	201889	737	3602	4813	312	213	90	56,05	0,428
2017-06-01	334686	1091	5565	7093	488	324	176	60,14	0,440
2017-07-01	595275	1646	9524	35963	1820	910	1332	62,50	0,209
2017-08-01	650039	1756	10403	36944	1870	934	50	62,49	0,220
2017-09-01	395318	1355	7069	41012	1899	954	29	55,92	0,147
2017-10-01	174520	868	3924	46262	1918	966	19	44,47	0,078
2017-11-01	124767	755	2946	44670	1943	978	25	42,35	0,062
2017-12-01	129780	774	2641	46681	1997	1004	54	49,14	0,054
2018-01-01	230696	983	4096	43981	1987	1006	-10	56,32	0,085
2018-02-01	104025	642	2379	40869	2041	1043	54	43,73	0,055
2018-03-01	174551	982	4281	44430	2121	1097	80	40,77	0,088
2018-04-01	202787	1294	5234	44502	2271	1173	150	38,74	0,105
2018-05-01	318040	1515	6885	50350	2433	1275	162	46,19	0,120
2018-06-01	842884	3090	13216	55084	2836	1483	403	63,78	0,193
2018-07-01	978220	3235	16368	56327	2997	1571	161	59,76	0,225
2018-08-01	929363	3134	17913	56660	3072	1617	75	51,88	0,240
2018-09-01	566294	2345	12585	61395	3114	1648	42	45,00	0,170
2018-10-01	272945	1494	6883	67552	3127	1674	13	39,65	0,092
2018-11-01	147202	1112	3861	65185	3119	1689	-8	38,13	0,056
2018-12-01	173507	1163	4706	66695	3141	1714	22	36,87	0,066
2019-01-01	290450	1402	6385	65442	3166	1737	25	45,49	0,089
2019-02-01	151161	949	3900	59411	3190	1745	24	38,76	0,062
2019-03-01	214071	1406	5898	63662	3213	1766	23	36,30	0,085
2019-04-01	261383	1694	7243	61141	3252	1790	39	36,09	0,106
2019-05-01	446797	2155	10401	67392	3436	1887	184	42,96	0,134
2019-06-01	638250	2530	13907	68507	3596	1978	160	45,89	0,169
2019-07-01	1091738	3989	21046	65025	3713	2020	117	51,87	0,245
2019-08-01	1355070	7089	26465	58065	3727	2040	14	51,20	0,313
2019-09-01	1020635	5539	21060	55913	3692	2045	-35	48,46	0,274
2019-10-01	373328	3004	9440	71501	3697	2068	5	39,55	0,117
2019-11-01	390810	3873	10625	67662	3626	2056	-71	36,78	0,136
2019-12-01	430115	1947	10718	70459	3689	2095	63	40,13	0,132

Annunci per tipologia	Anno 2017	% 2017	Anno 2018	% 2018	Anno 2019	% 2019
Entire home/apt	1812	85.1%	3132	86.2%	3994	85.8%
Private room	271	12.7%	403	11.1%	488	10.5%
Shared room	44	2.1%	75	2.1%	125	2.7%
Hotel room	2	0.1%	24	0.7%	49	1.1%
Total	2129		3634		4656	

## 6.6 Constant Mean Return

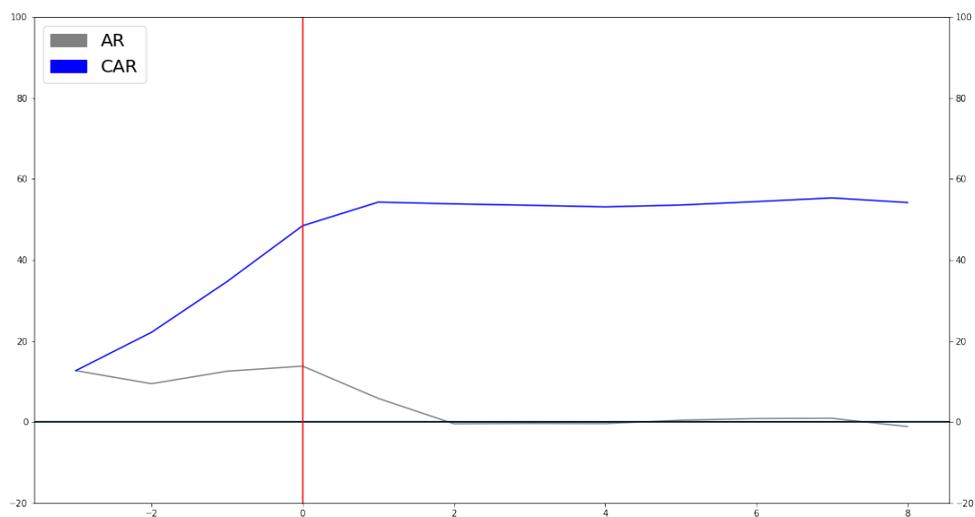
### 6.6.1 San Pietroburgo

- Andamento Average Daily Rate - Average Daily Rate Constant



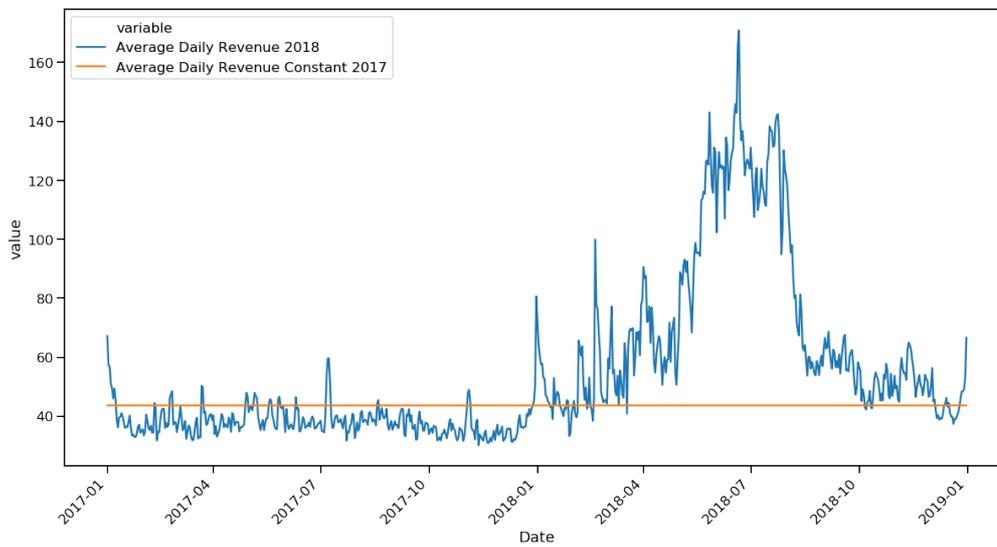
- Output analitico (AR, CAR, T-Test) e andamento AR-CAR

Period	Average Daily Revenue 2018	Average Daily Revenue Constant 2017	AR	CAR	Std.dev. AR	T-Test	Significant
-3	71.855725	59.173297	12.682428	12.682428	5.957042	2.128981	Si
-2	68.624901	59.173297	9.451604	22.134032	5.957042	1.586627	None
-1	71.709478	59.173297	12.536181	34.670213	5.957042	2.104430	Si
0	72.967769	59.173297	13.794473	48.464686	5.957042	2.315658	Si
1	64.998604	59.173297	5.825307	54.289994	5.957042	0.977886	None
2	58.740950	59.173297	-0.432346	53.857647	5.957042	-0.072577	None
3	58.826101	59.173297	-0.347196	53.510452	5.957042	-0.058283	None
4	58.784535	59.173297	-0.388761	53.121691	5.957042	-0.065261	None
5	59.623935	59.173297	0.450639	53.572329	5.957042	0.075648	None
6	60.017489	59.173297	0.844192	54.416522	5.957042	0.141713	None
7	60.089281	59.173297	0.915985	55.332506	5.957042	0.153765	None
8	58.031685	59.173297	-1.141612	54.190894	5.957042	-0.191641	None



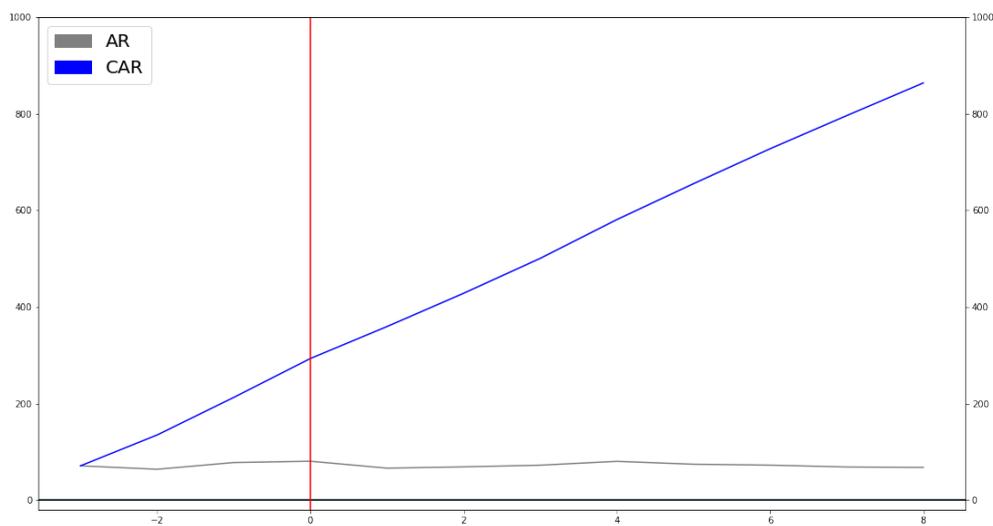
## 6.6.2 Nizhnij Novgorod

- Andamento Average Daily Rate - Average Daily Rate Constant



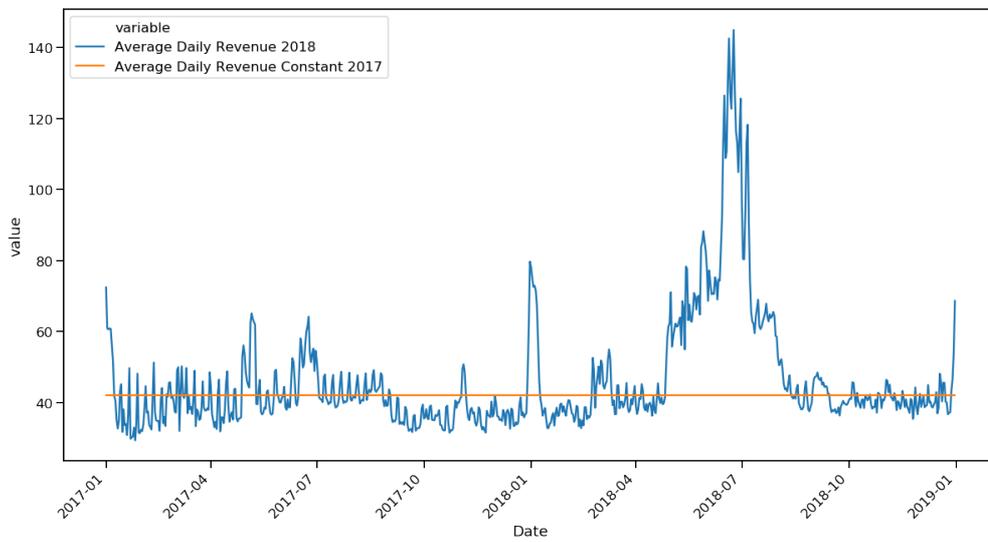
- Output analitico (AR, CAR, T-Test) e andamento AR-CAR

Period	Average Daily Revenue 2018	Average Daily Revenue Constant 2017	AR	CAR	Std.dev. AR	T-Test	Significant
-3	114.683516	43.671574	71.011943	71.011943	5.40238	13.144565	Si
-2	107.569536	43.671574	63.897963	134.909906	5.40238	11.827742	Si
-1	121.478183	43.671574	77.806610	212.716515	5.40238	14.402283	Si
0	124.197183	43.671574	80.525609	293.242125	5.40238	14.905579	Si
1	109.857333	43.671574	66.185760	359.427884	5.40238	12.251221	Si
2	112.546667	43.671574	68.875093	428.302977	5.40238	12.749027	Si
3	115.987212	43.671574	72.315639	500.618616	5.40238	13.385884	Si
4	123.946341	43.671574	80.274768	580.893384	5.40238	14.859147	Si
5	117.970297	43.671574	74.298723	655.192107	5.40238	13.752960	Si
6	116.076739	43.671574	72.405165	727.597272	5.40238	13.402456	Si
7	112.277273	43.671574	68.605699	796.202971	5.40238	12.699161	Si
8	111.322870	43.671574	67.651296	863.854267	5.40238	12.522498	Si



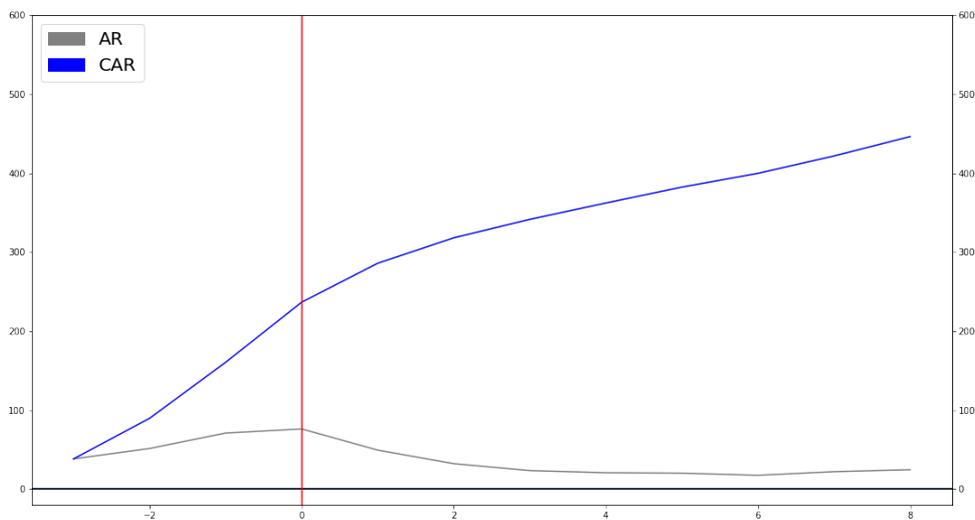
### 6.6.3 Kazan

- Andamento Average Daily Rate - Average Daily Rate Constant



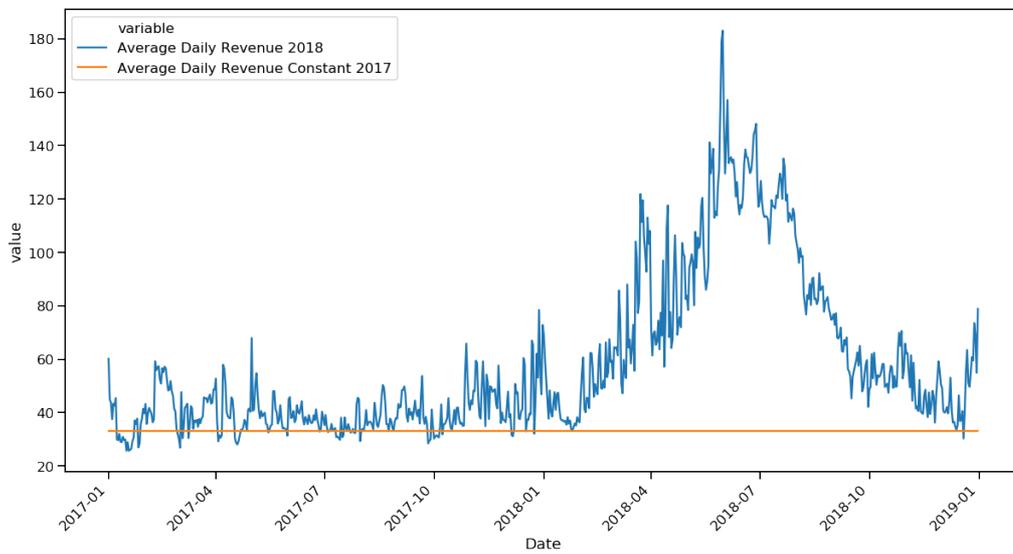
- Output analítico (AR, CAR, T-Test) e andamento AR-CAR

Period	Average Daily Revenue 2018	Average Daily Revenue Constant 2017	AR	CAR	Std.dev. AR	T-Test	Significant
-3	80.370238	42.145593	38.224645	38.224645	20.372835	1.876256	None
-2	93.540468	42.145593	51.394875	89.619520	20.372835	2.522716	Si
-1	113.072345	42.145593	70.926753	160.546273	20.372835	3.481438	Si
0	118.278970	42.145593	76.133377	236.679651	20.372835	3.737005	Si
1	91.425634	42.145593	49.280041	285.959692	20.372835	2.418909	Si
2	74.299544	42.145593	32.153952	318.113644	20.372835	1.578276	None
3	65.521127	42.145593	23.375534	341.489178	20.372835	1.147387	None
4	62.835396	42.145593	20.689803	362.178981	20.372835	1.015558	None
5	62.268015	42.145593	20.122423	382.301404	20.372835	0.987709	None
6	59.587863	42.145593	17.442271	399.743675	20.372835	0.856153	None
7	64.152985	42.145593	22.007392	421.751067	20.372835	1.080232	None
8	66.625000	42.145593	24.479407	446.230474	20.372835	1.201571	None



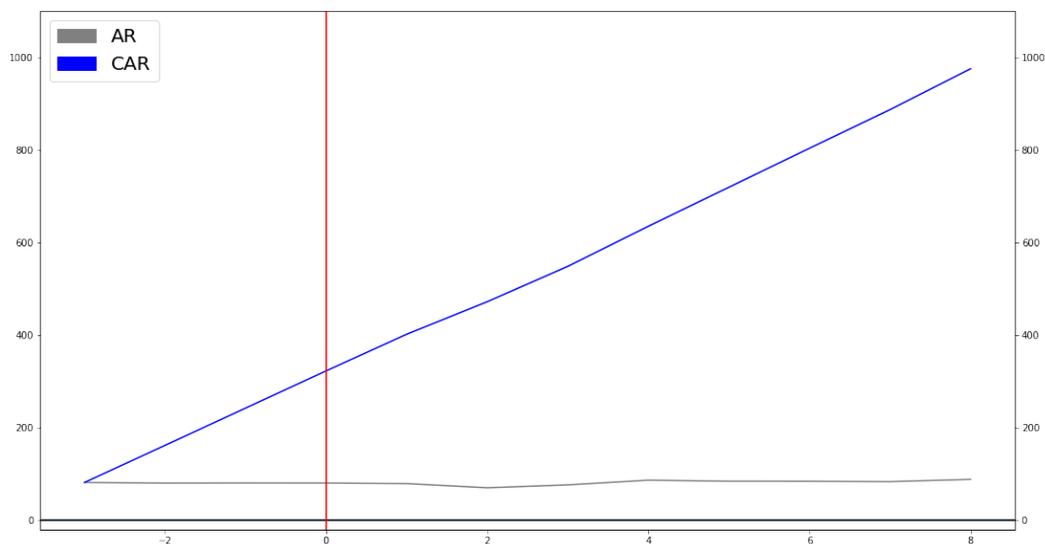
### 6.6.4 Samara

- Andamento Average Daily Rate - Average Daily Rate Constant



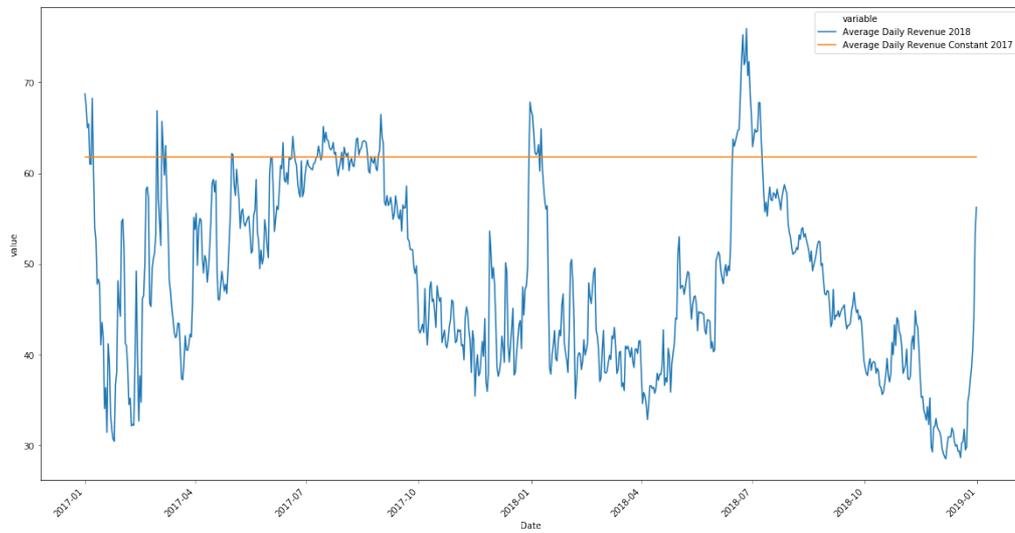
- Output analítico (AR, CAR, T-Test) e andamento AR-CAR

Period	Average Daily Revenue 2018	Average Daily Revenue Constant 2017	AR	CAR	Std.dev. AR	T-Test	Significant
-3	114.687500	33.023186	81.664314	81.664314	4.798793	17.017677	Si
-2	113.189189	33.023186	80.166003	161.830316	4.798793	16.705451	Si
-1	113.526385	33.023186	80.503199	242.333515	4.798793	16.775717	Si
0	113.386035	33.023186	80.362849	322.696364	4.798793	16.746470	Si
1	112.158479	33.023186	79.135292	401.831656	4.798793	16.490665	Si
2	103.220000	33.023186	70.196814	472.028469	4.798793	14.628014	Si
3	109.395189	33.023186	76.372003	548.400472	4.798793	15.914835	Si
4	119.578755	33.023186	86.555568	634.956040	4.798793	18.036945	Si
5	117.330961	33.023186	84.307774	719.263814	4.798793	17.568537	Si
6	117.161716	33.023186	84.138530	803.402344	4.798793	17.533268	Si
7	116.442953	33.023186	83.419767	886.822110	4.798793	17.383488	Si
8	121.318182	33.023186	88.294995	975.117106	4.798793	18.399417	Si



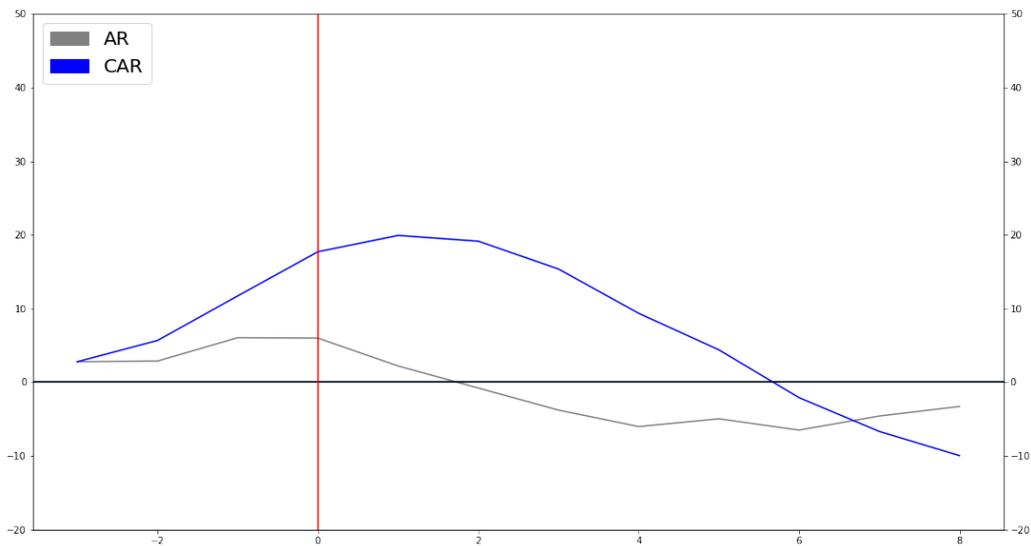
### 6.6.5 Sochi

- Andamento Average Daily Rate - Average Daily Rate Constant



- Output analitico (AR, CAR, T-Test) e andamento AR-CAR

Period	Average Daily Revenue 2018	Average Daily Revenue Constant 2017	AR	CAR	Std.dev. AR	T-Test	Significant
-3	64.538126	61.749352	2.788775	2.788775	4.618398	0.603840	None
-2	64.627530	61.749352	2.878179	5.666953	4.618398	0.623199	None
-1	67.795681	61.749352	6.046329	11.713283	4.618398	1.309183	None
0	67.744479	61.749352	5.995128	17.708411	4.618398	1.298097	None
1	63.963370	61.749352	2.214018	19.922429	4.618398	0.479391	None
2	60.969880	61.749352	-0.779472	19.142957	4.618398	-0.168775	None
3	57.973856	61.749352	-3.775495	15.367461	4.618398	-0.817490	None
4	55.739785	61.749352	-6.009567	9.357895	4.618398	-1.301223	None
5	56.790497	61.749352	-4.958855	4.399040	4.618398	-1.073718	None
6	55.262605	61.749352	-6.486747	-2.087707	4.618398	-1.404545	None
7	57.167715	61.749352	-4.581637	-6.669344	4.618398	-0.992040	None
8	58.465839	61.749352	-3.283513	-9.952857	4.618398	-0.710964	None



## 6.7 Trend Model

### 6.7.1 San Pietroburgo

- Output prodotto

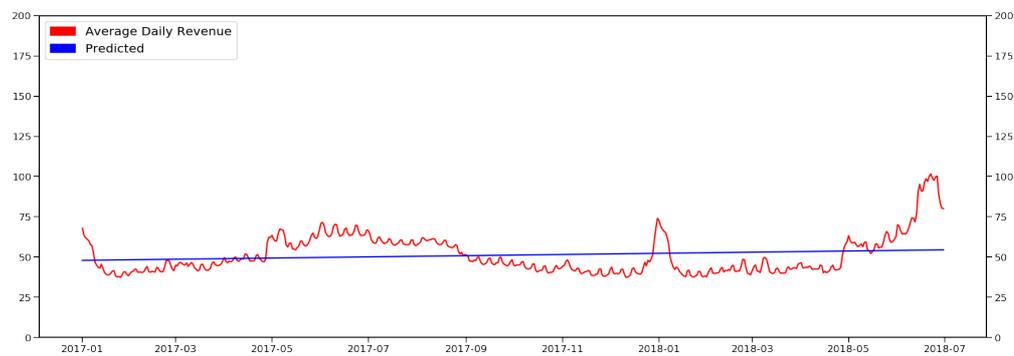
OLS Regression Results

```

=====
Dep. Variable:   Average Daily Revenue   R-squared:         0.024
Model:          OLS                     Adj. R-squared:    0.023
Method:         Least Squares           F-statistic:       1.373
Date:           Sun, 04 Oct 2020         Prob (F-statistic): 0.242
Time:           19:35:35                 Log-Likelihood:    -2129.9
No. Observations: 546                   AIC:               4264.
Df Residuals:   544                     BIC:               4272.
Df Model:       1
Covariance Type: HAC
=====

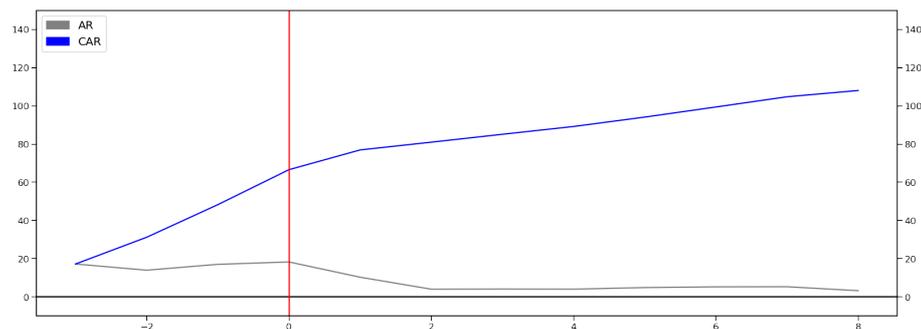
```

	coef	std err	t	P> t	[0.025	0.975]
const	47.9400	2.388	20.072	0.000	43.248	52.632
Trend	0.0120	0.010	1.172	0.242	-0.008	0.032



- AR, CAR, T-Test e andamento AR-CAR

Period	Average Daily Revenue	Predicted	Date	AR	CAR	STD AR	T-Test AR	Significant
-3	71.855725	54.622083	2018-07-11	17.233642	17.233642	5.993339	2.875466	Si
-2	68.624901	54.634079	2018-07-12	13.990821	31.224463	5.993339	2.334395	Si
-1	71.709478	54.646076	2018-07-13	17.063402	48.287865	5.993339	2.847061	Si
0	72.967769	54.658073	2018-07-14	18.309697	66.597562	5.993339	3.055008	Si
1	64.998604	54.670069	2018-07-15	10.328535	76.926096	5.993339	1.723336	None
2	58.740950	54.682066	2018-07-16	4.058885	80.984981	5.993339	0.677233	None
3	58.826101	54.694062	2018-07-17	4.132039	85.117020	5.993339	0.689439	None
4	58.784535	54.706059	2018-07-18	4.078476	89.195496	5.993339	0.680502	None
5	59.623935	54.718056	2018-07-19	4.905880	94.101376	5.993339	0.818555	None
6	60.017489	54.730052	2018-07-20	5.287437	99.388813	5.993339	0.882219	None
7	60.089281	54.742049	2018-07-21	5.347232	104.736045	5.993339	0.892196	None
8	58.031685	54.754045	2018-07-22	3.277639	108.013684	5.993339	0.546880	None



## 6.7.2 Nizhnij Novgorod

- Output prodotto

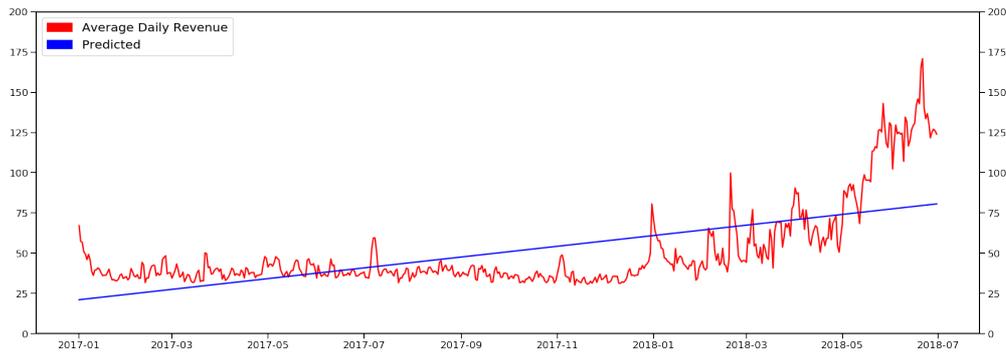
OLS Regression Results

```

=====
Dep. Variable:   Average Daily Revenue   R-squared:         0.429
Model:          OLS                     Adj. R-squared:    0.428
Method:         Least Squares           F-statistic:       36.74
Date:           Sun, 04 Oct 2020         Prob (F-statistic): 2.52e-09
Time:           19:39:59                 Log-Likelihood:    -2406.7
No. Observations: 546                   AIC:               4817.
Df Residuals:   544                     BIC:               4826.
Df Model:       1
Covariance Type: HAC
=====

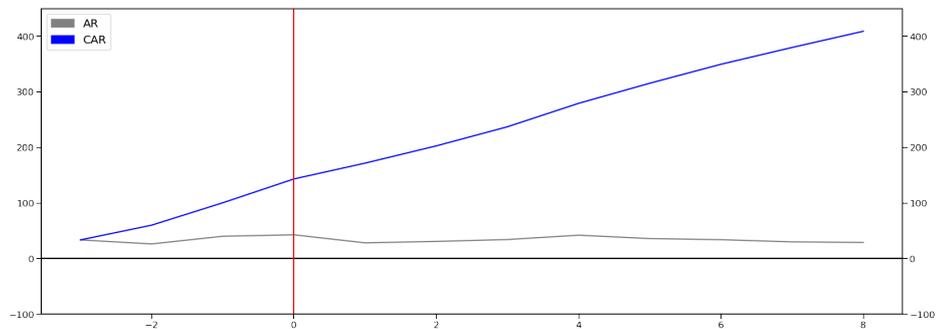
```

	coef	std err	t	P> t	[0.025	0.975]
const	21.0193	3.836	5.480	0.000	13.485	28.554
Trend	0.1092	0.018	6.062	0.000	0.074	0.145



- AR, CAR, T-Test e andamento AR-CAR

Period	Average Daily Revenue	Predicted	Date	AR	CAR	STD AR	T-Test AR	Significant
-3	114.683516	80.982241	2018-07-03	33.701275	33.701275	5.433036	6.203028	Si
-2	107.569536	81.091463	2018-07-04	26.478073	60.179348	5.433036	4.873532	Si
-1	121.478183	81.200686	2018-07-05	40.277498	100.456846	5.433036	7.413442	Si
0	124.197183	81.309908	2018-07-06	42.887275	143.344122	5.433036	7.893795	Si
1	109.857333	81.419130	2018-07-07	28.438204	171.782325	5.433036	5.234312	Si
2	112.546667	81.528352	2018-07-08	31.018315	202.800640	5.433036	5.709205	Si
3	115.987212	81.637574	2018-07-09	34.349638	237.150279	5.433036	6.322365	Si
4	123.946341	81.746796	2018-07-10	42.199546	279.349824	5.433036	7.767212	Si
5	117.970297	81.856018	2018-07-11	36.114279	315.464103	5.433036	6.647163	Si
6	116.076739	81.965240	2018-07-12	34.111499	349.575602	5.433036	6.278533	Si
7	112.277273	82.074462	2018-07-13	30.202811	379.778412	5.433036	5.559104	Si
8	111.322870	82.183684	2018-07-14	29.139186	408.917598	5.433036	5.363334	Si



### 6.7.3 Kazan

- Output prodotto

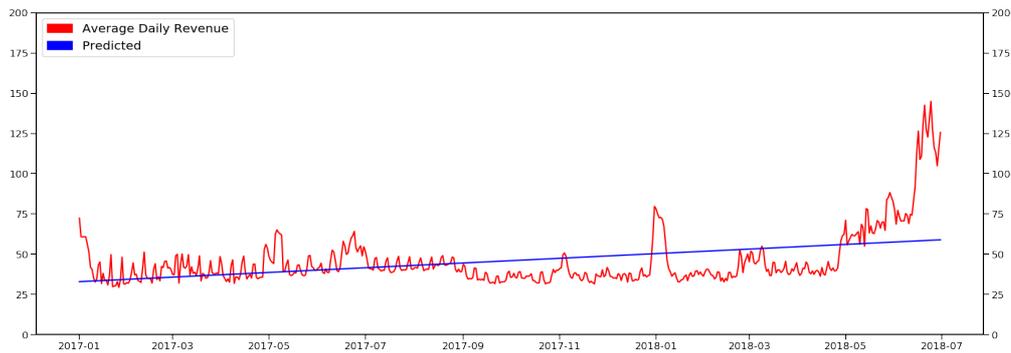
**OLS Regression Results**

```

=====
Dep. Variable:   Average Daily Revenue   R-squared:         0.183
Model:          OLS                     Adj. R-squared:    0.181
Method:         Least Squares           F-statistic:       10.25
Date:           Sun, 04 Oct 2020        Prob (F-statistic): 0.00145
Time:           19:40:40                Log-Likelihood:    -2285.5
No. Observations: 546                   AIC:               4575.
Df Residuals:   544                     BIC:               4584.
Df Model:       1
Covariance Type: HAC
=====

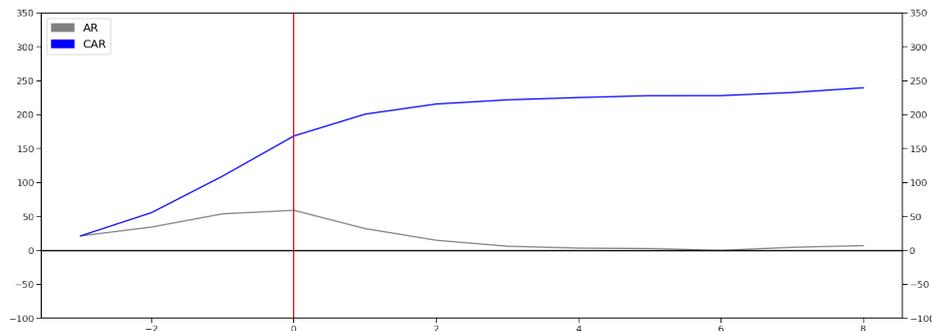
```

	coef	std err	t	P> t	[0.025	0.975]
const	32.9148	2.976	11.059	0.000	27.069	38.761
Trend	0.0477	0.015	3.201	0.001	0.018	0.077



- AR, CAR, T-Test e andamento AR-CAR

Period	Average Daily Revenue	Predicted	Date	AR	CAR	STD AR	T-Test AR	Significant
-3	80.370238	59.106490	2018-07-03	21.263748	21.263748	20.497154	1.037400	None
-2	93.540468	59.154198	2018-07-04	34.386270	55.650018	20.497154	1.677612	None
-1	113.072345	59.201906	2018-07-05	53.870440	109.520458	20.497154	2.628191	Si
0	118.278970	59.249614	2018-07-06	59.029356	168.549814	20.497154	2.879881	Si
1	91.425634	59.297322	2018-07-07	32.128312	200.678126	20.497154	1.567452	None
2	74.299544	59.345030	2018-07-08	14.954514	215.632640	20.497154	0.729590	None
3	65.521127	59.392738	2018-07-09	6.128389	221.761029	20.497154	0.298987	None
4	62.835396	59.440446	2018-07-10	3.394950	225.155978	20.497154	0.165630	None
5	62.268015	59.488154	2018-07-11	2.779861	227.935839	20.497154	0.135622	None
6	59.587863	59.535862	2018-07-12	0.052001	227.987840	20.497154	0.002537	None
7	64.152985	59.583571	2018-07-13	4.569415	232.557255	20.497154	0.222929	None
8	66.625000	59.631279	2018-07-14	6.993721	239.550976	20.497154	0.341205	None



## 6.7.4 Samara

- Output prodotto

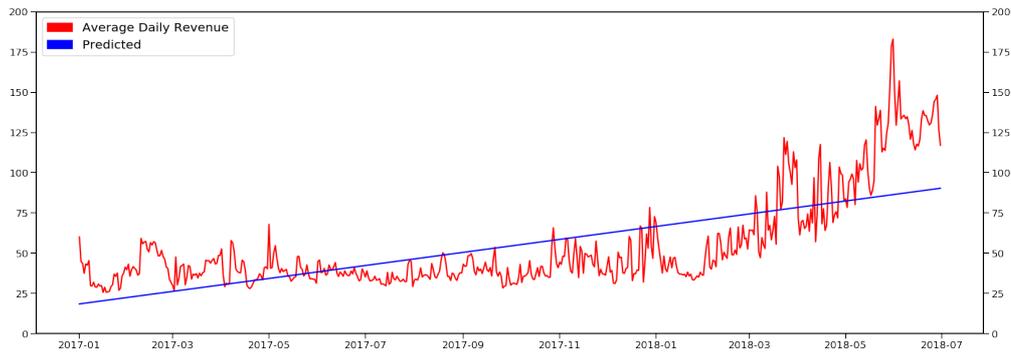
**OLS Regression Results**

```

=====
Dep. Variable:   Average Daily Revenue   R-squared:         0.488
Model:          OLS                     Adj. R-squared:    0.487
Method:         Least Squares           F-statistic:       49.24
Date:           Sun, 04 Oct 2020         Prob (F-statistic): 6.76e-12
Time:           19:35:39                 Log-Likelihood:    -2444.8
No. Observations: 546                   AIC:               4894.
Df Residuals:   544                     BIC:               4902.
Df Model:       1
Covariance Type: HAC
=====

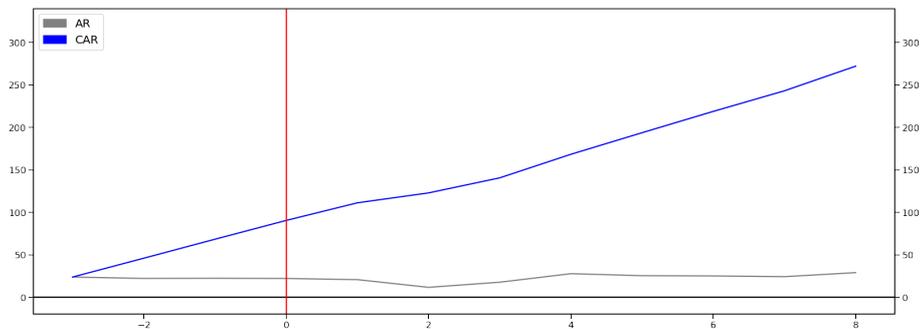
```

	coef	std err	t	P> t	[0.025	0.975]
const	18.3950	4.267	4.311	0.000	10.013	26.777
Trend	0.1318	0.019	7.017	0.000	0.095	0.169



- AR, CAR, T-Test e andamento AR-CAR

Period	Average Daily Revenue	Predicted	Date	AR	CAR	STD AR	T-Test AR	Significant
-3	114.687500	90.889025	2018-07-04	23.798475	23.798475	4.59863	5.175123	Si
-2	113.189189	91.020832	2018-07-05	22.168357	45.966833	4.59863	4.820644	Si
-1	113.526385	91.152639	2018-07-06	22.373746	68.340578	4.59863	4.865307	Si
0	113.386035	91.284447	2018-07-07	22.101589	90.442167	4.59863	4.806125	Si
1	112.158479	91.416254	2018-07-08	20.742225	111.184392	4.59863	4.510523	Si
2	103.220000	91.548061	2018-07-09	11.671939	122.856330	4.59863	2.538134	Si
3	109.395189	91.679869	2018-07-10	17.715320	140.571651	4.59863	3.852304	Si
4	119.578755	91.811676	2018-07-11	27.767079	168.338729	4.59863	6.038120	Si
5	117.330961	91.943483	2018-07-12	25.387478	193.726207	4.59863	5.520661	Si
6	117.161716	92.075291	2018-07-13	25.086426	218.812633	4.59863	5.455196	Si
7	116.442953	92.207098	2018-07-14	24.235855	243.048488	4.59863	5.270234	Si
8	121.318182	92.338905	2018-07-15	28.979277	272.027764	4.59863	6.301720	Si



## 6.7.5 Sochi

- Output prodotto

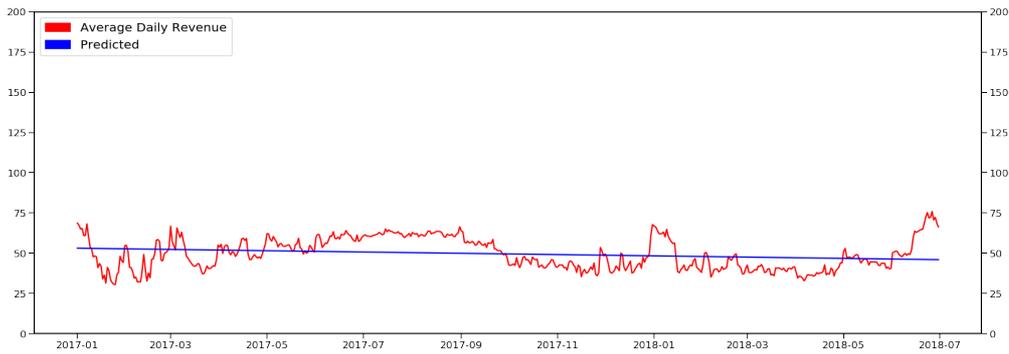
OLS Regression Results

```

=====
Dep. Variable:   Average Daily Revenue   R-squared:         0.045
Model:          OLS                     Adj. R-squared:    0.043
Method:         Least Squares           F-statistic:       2.927
Date:           Sun, 04 Oct 2020        Prob (F-statistic): 0.0877
Time:           19:35:45                Log-Likelihood:    -2002.7
No. Observations: 546                   AIC:               4009.
Df Residuals:   544                     BIC:               4018.
Df Model:        1
Covariance Type: HAC
=====

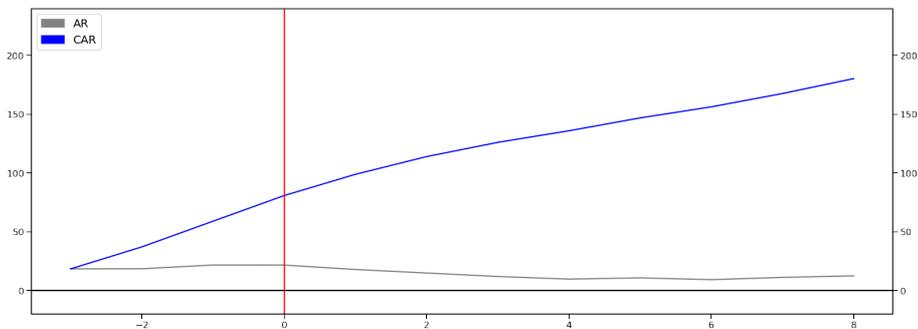
```

	coef	std err	t	P> t	[0.025	0.975]
const	53.1519	2.285	23.266	0.000	48.664	57.639
Trend	-0.0131	0.008	-1.711	0.088	-0.028	0.002



- AR, CAR, T-Test e andamento AR-CAR

Period	Average Daily Revenue	Predicted	Date	AR	CAR	STD AR	T-Test AR	Significant
-3	64.538126	45.965660	2018-07-04	18.572466	18.572466	4.579367	4.055684	Si
-2	64.627530	45.952594	2018-07-05	18.674936	37.247402	4.579367	4.078060	Si
-1	67.795681	45.939528	2018-07-06	21.856153	59.103555	4.579367	4.772745	Si
0	67.744479	45.926463	2018-07-07	21.818017	80.921572	4.579367	4.764417	Si
1	63.963370	45.913397	2018-07-08	18.049973	98.971545	4.579367	3.941587	Si
2	60.969880	45.900331	2018-07-09	15.069549	114.041094	4.579367	3.290749	Si
3	57.973856	45.887265	2018-07-10	12.086591	126.127685	4.579367	2.639358	Si
4	55.739785	45.874199	2018-07-11	9.865586	135.993271	4.579367	2.154356	Si
5	56.790497	45.861133	2018-07-12	10.929363	146.922635	4.579367	2.386654	Si
6	55.262605	45.848067	2018-07-13	9.414538	156.337172	4.579367	2.055860	Si
7	57.167715	45.835002	2018-07-14	11.332713	167.669886	4.579367	2.474733	Si
8	58.465839	45.821936	2018-07-15	12.643903	180.313788	4.579367	2.761059	Si



## 6.8 Trend and Seasonality Model

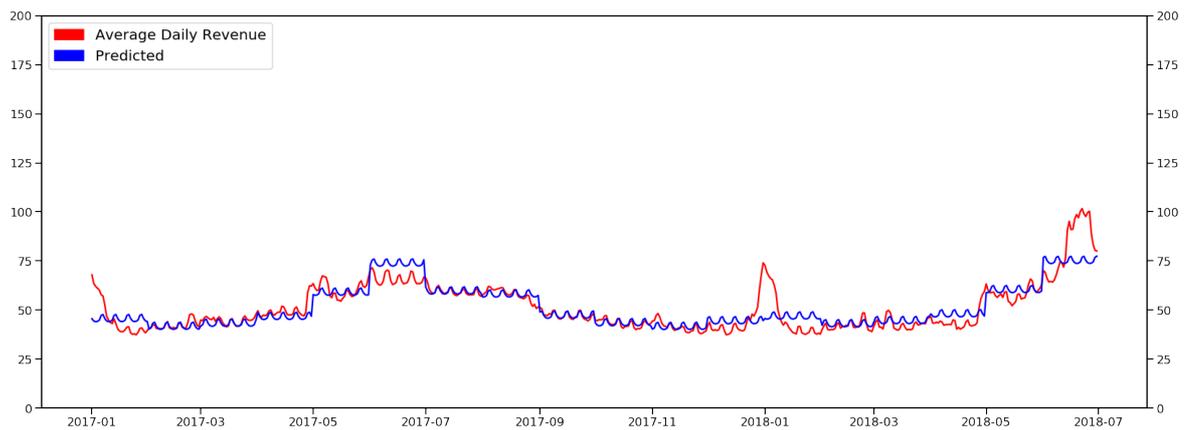
### 6.8.1 San Pietroburgo

- Output prodotto

#### OLS Regression Results

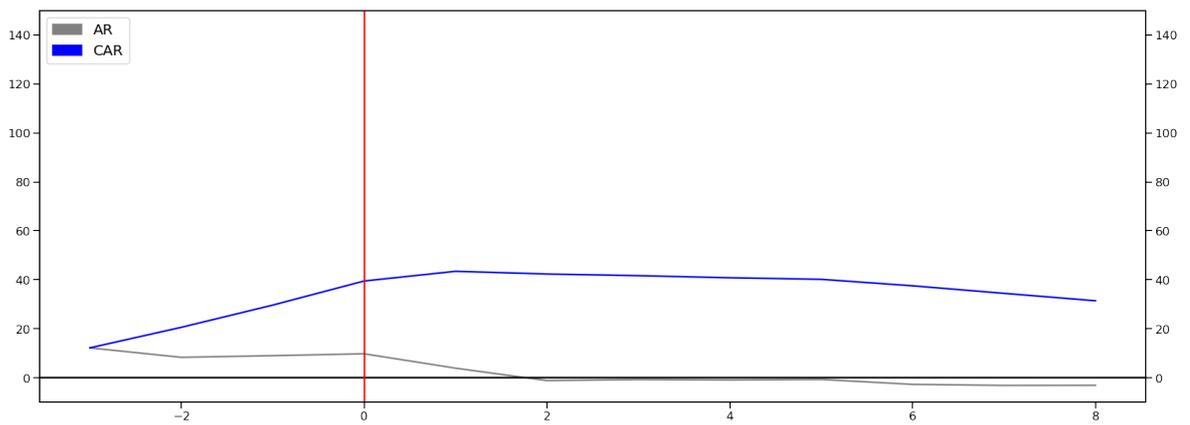
Dep. Variable:	Average Daily Revenue	R-squared:	0.733
Model:	OLS	Adj. R-squared:	0.724
Method:	Least Squares	F-statistic:	76.39
Date:	Sun, 04 Oct 2020	Prob (F-statistic):	6.63e-134
Time:	23:16:40	Log-Likelihood:	-1776.5
No. Observations:	546	AIC:	3591.
Df Residuals:	527	BIC:	3673.
Df Model:	18		
Covariance Type:	HAC		

	coef	std err	t	P> t	[0.025	0.975]
const	40.7871	1.270	32.124	0.000	38.293	43.281
Trend	0.0036	0.005	0.735	0.463	-0.006	0.013
gen	4.0283	2.983	1.350	0.177	-1.832	9.888
mar	1.4674	0.797	1.840	0.066	-0.099	3.034
apr	4.8203	1.497	3.221	0.001	1.880	7.760
mag	17.0528	1.209	14.100	0.000	14.677	19.429
giu	31.7801	3.775	8.419	0.000	24.364	39.196
lug	17.4377	0.708	24.636	0.000	16.047	18.828
ago	15.7968	1.228	12.864	0.000	13.384	18.209
set	4.9040	0.621	7.900	0.000	3.684	6.124
ott	0.9453	0.840	1.126	0.261	-0.705	2.595
nov	-1.0332	1.143	-0.904	0.366	-3.278	1.212
dic	1.7179	2.841	0.605	0.546	-3.864	7.300
lun	2.8922	0.474	6.104	0.000	1.961	3.823
mer	2.4015	0.351	6.836	0.000	1.711	3.092
gio	-0.6235	0.359	-1.735	0.083	-1.330	0.082
ven	-0.7495	0.490	-1.529	0.127	-1.712	0.214
sab	-0.4083	0.549	-0.744	0.457	-1.487	0.670
dom	0.7866	0.580	1.356	0.176	-0.353	1.927



- AR, CAR, T-Test e andamento AR-CAR

Period	Average Daily Revenue	Predicted	Date	AR	CAR	STD AR	T-Test AR	Significant
-3	71.855725	59.610338	2018-07-11	12.245387	12.245387	5.726983	2.138191	Si
-2	68.624901	60.237490	2018-07-12	8.387410	20.632797	5.726983	1.464542	None
-1	71.709478	62.642581	2018-07-13	9.066897	29.699694	5.726983	1.583189	None
0	72.967769	63.136901	2018-07-14	9.830868	39.530562	5.726983	1.716588	None
1	64.998604	61.034898	2018-07-15	3.963706	43.494268	5.726983	0.692111	None
2	58.740950	59.843586	2018-07-16	-1.102635	42.391633	5.726983	-0.192533	None
3	58.826101	59.506047	2018-07-17	-0.679946	41.711687	5.726983	-0.118727	None
4	58.784535	59.635587	2018-07-18	-0.851052	40.860636	5.726983	-0.148604	None
5	59.623935	60.262740	2018-07-19	-0.638805	40.221831	5.726983	-0.111543	None
6	60.017489	62.667831	2018-07-20	-2.650342	37.571489	5.726983	-0.462781	None
7	60.089281	63.162150	2018-07-21	-3.072869	34.498620	5.726983	-0.536560	None
8	58.031685	61.060147	2018-07-22	-3.028462	31.470158	5.726983	-0.528806	None



## 6.8.2 Nizhnij Novgorod

- Output prodotto

### OLS Regression Results

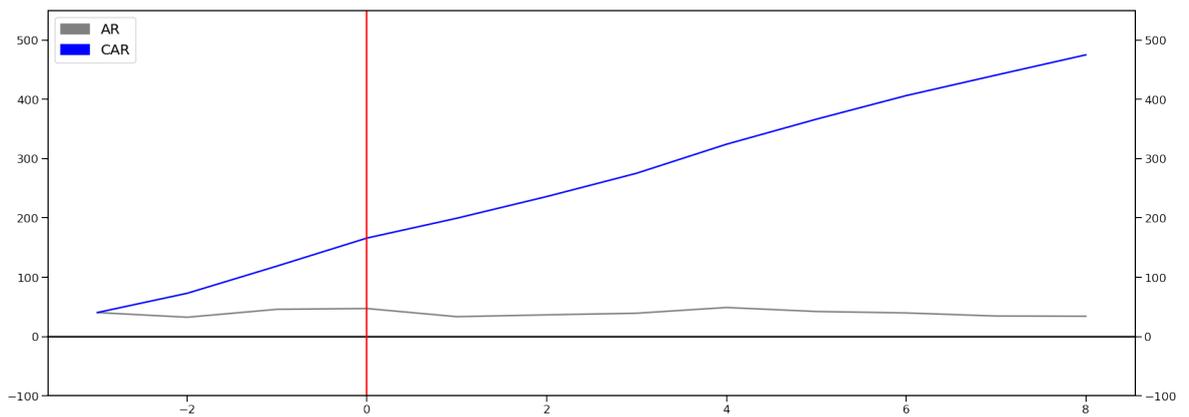
Dep. Variable:	Average Daily Revenue	R-squared:	0.680
Model:	OLS	Adj. R-squared:	0.669
Method:	Least Squares	F-statistic:	14.56
Date:	Sun, 04 Oct 2020	Prob (F-statistic):	6.57e-36
Time:	23:22:48	Log-Likelihood:	-2248.5
No. Observations:	546	AIC:	4535.
Df Residuals:	527	BIC:	4617.
Df Model:	18		
Covariance Type:	HAC		

	coef	std err	t	P> t	[0.025	0.975]
const	22.4416	4.886	4.593	0.000	12.843	32.040
Trend	0.1021	0.013	8.123	0.000	0.077	0.127
gen	1.0699	6.688	0.160	0.873	-12.069	14.209
mar	-0.2874	4.893	-0.059	0.953	-9.899	9.325
apr	-0.0488	4.819	-0.010	0.992	-9.516	9.419
mag	16.1049	6.591	2.443	0.015	3.156	29.053
giu	25.7517	10.314	2.497	0.013	5.491	46.013
lug	-3.1295	4.654	-0.672	0.502	-12.272	6.013
ago	-6.6523	4.143	-1.606	0.109	-14.791	1.487
set	-11.3504	4.224	-2.687	0.007	-19.648	-3.053
ott	-17.5778	4.253	-4.133	0.000	-25.932	-9.224
nov	-19.7412	4.712	-4.189	0.000	-28.998	-10.484
dic	-20.0001	5.007	-3.994	0.000	-29.836	-10.164
lun	0.5976	1.184	0.505	0.614	-1.728	2.923
mer	1.2994	0.876	1.483	0.139	-0.422	3.021
gio	-0.4383	0.709	-0.618	0.537	-1.831	0.955
ven	-1.0958	0.987	-1.110	0.268	-3.035	0.844
sab	0.7132	1.183	0.603	0.547	-1.611	3.037
dom	0.0956	1.296	0.074	0.941	-2.451	2.642



- AR, CAR, T-Test e andamento AR-CAR

Period	Average Daily Revenue	Predicted	Date	AR	CAR	STD AR	T-Test AR	Significant
-3	114.683516	74.295982	2018-07-03	40.387535	40.387535	5.588286	7.227177	Si
-2	107.569536	75.055711	2018-07-04	32.513825	72.901360	5.588286	5.818210	Si
-1	121.478183	75.596117	2018-07-05	45.882067	118.783427	5.588286	8.210400	Si
0	124.197183	76.997637	2018-07-06	47.199546	165.982973	5.588286	8.446158	Si
1	109.857333	76.398058	2018-07-07	33.459275	199.442248	5.588286	5.987395	Si
2	112.546667	75.998179	2018-07-08	36.548488	235.990736	5.588286	6.540196	Si
3	115.987212	76.717892	2018-07-09	39.269321	275.260056	5.588286	7.027078	Si
4	123.946341	75.011023	2018-07-10	48.935318	324.195375	5.588286	8.756767	Si
5	117.970297	75.770753	2018-07-11	42.199544	366.394919	5.588286	7.551429	Si
6	116.076739	76.311158	2018-07-12	39.765580	406.160499	5.588286	7.115881	Si
7	112.277273	77.712679	2018-07-13	34.564594	440.725093	5.588286	6.185187	Si
8	111.322870	77.113100	2018-07-14	34.209770	474.934863	5.588286	6.121693	Si



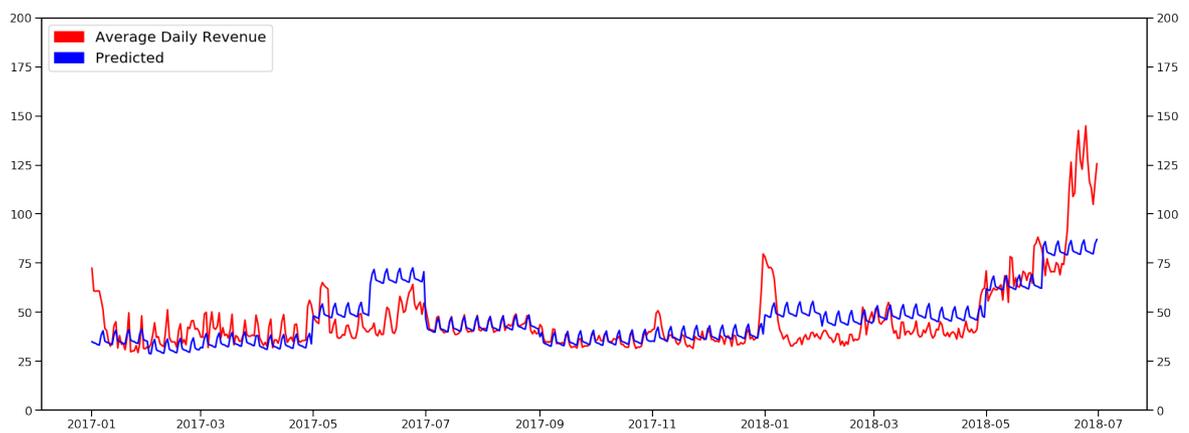
### 6.8.3 Kazan

- Output prodotto

#### OLS Regression Results

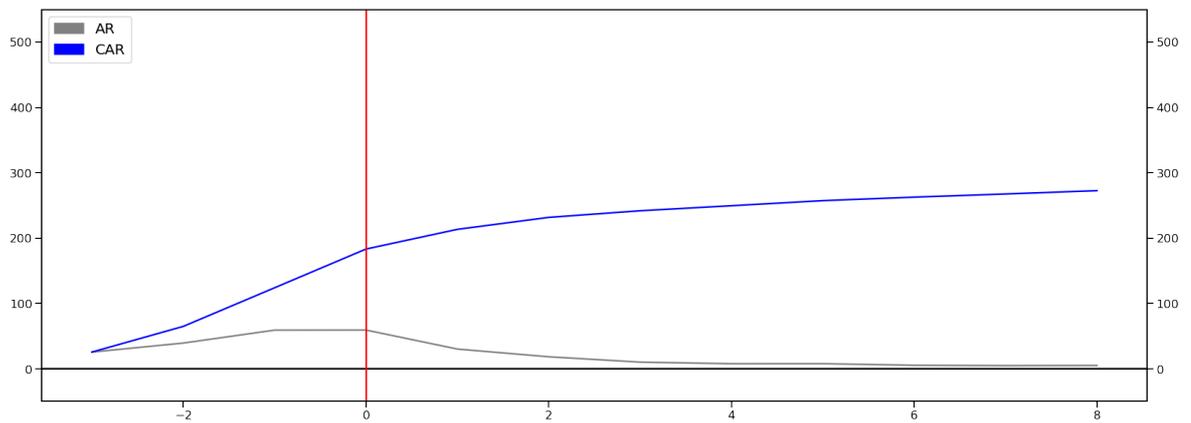
Dep. Variable:	Average Daily Revenue	R-squared:	0.560
Model:	OLS	Adj. R-squared:	0.545
Method:	Least Squares	F-statistic:	16.65
Date:	Sun, 04 Oct 2020	Prob (F-statistic):	6.12e-41
Time:	23:16:22	Log-Likelihood:	-2116.4
No. Observations:	546	AIC:	4271.
Df Residuals:	527	BIC:	4353.
Df Model:	18		
Covariance Type:	HAC		

	coef	std err	t	P> t	[0.025	0.975]
const	27.5463	3.574	7.707	0.000	20.525	34.568
Trend	0.0389	0.010	3.796	0.000	0.019	0.059
gen	5.5287	5.020	1.101	0.271	-4.333	15.390
mar	1.9391	3.469	0.559	0.576	-4.876	8.754
apr	-0.2219	3.564	-0.062	0.950	-7.223	6.779
mag	14.5677	3.894	3.741	0.000	6.917	22.218
giu	31.0322	8.896	3.488	0.001	13.556	48.508
lug	4.9602	2.732	1.816	0.070	-0.407	10.327
ago	4.6106	2.718	1.696	0.090	-0.729	9.950
set	-4.5789	2.827	-1.620	0.106	-10.133	0.975
ott	-5.2025	2.849	-1.826	0.068	-10.799	0.394
nov	-4.3375	3.374	-1.285	0.199	-10.966	2.291
dic	-4.7291	3.635	-1.301	0.194	-11.870	2.412
lun	7.2459	1.095	6.615	0.000	5.094	9.398
mer	5.0561	0.809	6.248	0.000	3.466	6.646
gio	0.3043	0.746	0.408	0.683	-1.161	1.769
ven	0.9760	0.887	1.100	0.272	-0.767	2.719
sab	1.2806	0.937	1.367	0.172	-0.560	3.121
dom	1.9049	1.107	1.721	0.086	-0.270	4.080



- AR, CAR, T-Test e andamento AR-CAR

Period	Average Daily Revenue	Predicted	Date	AR	CAR	STD AR	T-Test AR	Significant
-3	80.370238	54.847641	2018-07-03	25.522597	25.522597	20.350306	1.254163	None
-2	93.540468	54.214866	2018-07-04	39.325602	64.848199	20.350306	1.932433	None
-1	113.072345	53.949502	2018-07-05	59.122843	123.971042	20.350306	2.905256	Si
0	118.278970	59.044511	2018-07-06	59.234459	183.205501	20.350306	2.910741	Si
1	91.425634	61.273229	2018-07-07	30.152405	213.357906	20.350306	1.481668	None
2	74.299544	55.971127	2018-07-08	18.328417	231.686323	20.350306	0.900646	None
3	65.521127	55.385725	2018-07-09	10.135401	241.821725	20.350306	0.498047	None
4	62.835396	55.120057	2018-07-10	7.715339	249.537064	20.350306	0.379126	None
5	62.268015	54.487282	2018-07-11	7.780733	257.317798	20.350306	0.382340	None
6	59.587863	54.221918	2018-07-12	5.365945	262.683743	20.350306	0.263679	None
7	64.152985	59.316926	2018-07-13	4.836059	267.519802	20.350306	0.237641	None
8	66.625000	61.545645	2018-07-14	5.079355	272.599157	20.350306	0.249596	None



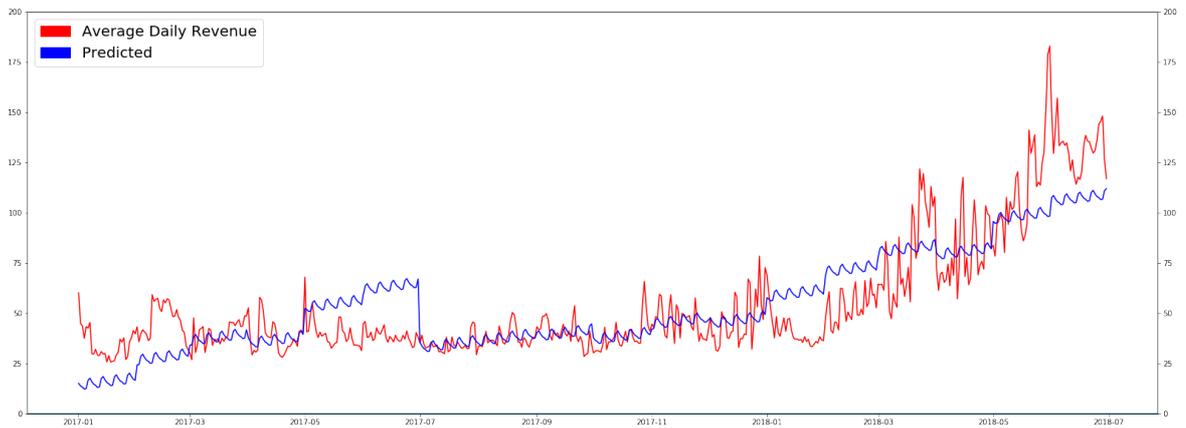
### 6.8.4 Samara

- Output prodotto

#### OLS Regression Results

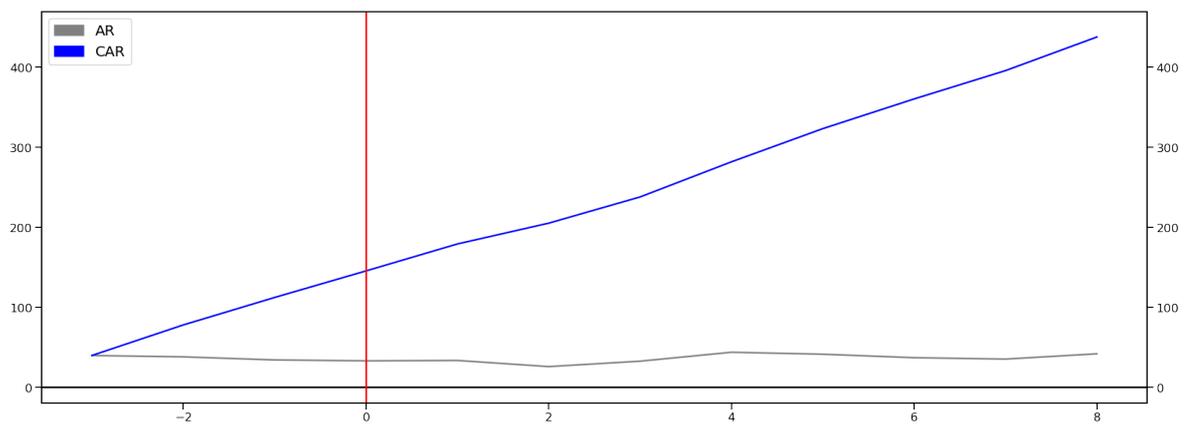
Dep. Variable:	Average Daily Revenue	R-squared:	0.674
Model:	OLS	Adj. R-squared:	0.663
Method:	Least Squares	F-statistic:	21.04
Date:	Sun, 04 Oct 2020	Prob (F-statistic):	7.02e-51
Time:	23:16:37	Log-Likelihood:	-2321.2
No. Observations:	546	AIC:	4680.
Df Residuals:	527	BIC:	4762.
Df Model:	18		
Covariance Type:	HAC		

	coef	std err	t	P> t	[0.025	0.975]
const	20.4231	8.019	2.547	0.011	4.670	36.176
Trend	0.1206	0.015	8.256	0.000	0.092	0.149
gen	-8.5965	9.611	-0.894	0.372	-27.477	10.284
mar	6.4164	8.202	0.782	0.434	-9.697	22.529
apr	1.4060	7.464	0.188	0.851	-13.256	16.068
mag	15.6505	9.521	1.644	0.101	-3.054	34.355
giu	20.7245	11.374	1.822	0.069	-1.620	43.069
lug	-11.8826	7.224	-1.645	0.101	-26.074	2.309
ago	-12.1599	7.259	-1.675	0.094	-26.419	2.100
set	-13.6413	7.468	-1.827	0.068	-28.313	1.030
ott	-18.8134	7.411	-2.539	0.011	-33.373	-4.254
nov	-14.9951	7.482	-2.004	0.046	-29.694	-0.297
dic	-18.2413	7.866	-2.319	0.021	-33.694	-2.789
lun	4.9590	1.836	2.700	0.007	1.352	8.566
mer	4.0549	1.547	2.622	0.009	1.017	7.093
gio	-0.0871	1.408	-0.062	0.951	-2.853	2.678
ven	1.0101	1.490	0.678	0.498	-1.918	3.938
sab	1.7215	1.717	1.002	0.317	-1.652	5.095
dom	3.1044	1.877	1.654	0.099	-0.583	6.792



- AR, CAR, T-Test e andamento AR-CAR

Period	Average Daily Revenue	Predicted	Date	AR	CAR	STD AR	T-Test AR	Significant
-3	114.687500	74.801359	2018-07-04	39.886141	39.886141	4.989196	7.994502	Si
-2	113.189189	75.009105	2018-07-05	38.180085	78.066226	4.989196	7.652552	Si
-1	113.526385	79.184628	2018-07-06	34.341758	112.407984	4.989196	6.883224	Si
0	113.386035	80.209339	2018-07-07	33.176697	145.584680	4.989196	6.649707	Si
1	112.158479	78.475411	2018-07-08	33.683068	179.267748	4.989196	6.751201	Si
2	103.220000	77.213110	2018-07-09	26.006890	205.274638	4.989196	5.212641	Si
3	109.395189	76.622354	2018-07-10	32.772835	238.047472	4.989196	6.568760	Si
4	119.578755	75.645788	2018-07-11	43.932967	281.980439	4.989196	8.805620	Si
5	117.330961	75.853534	2018-07-12	41.477427	323.457867	4.989196	8.313448	Si
6	117.161716	80.029056	2018-07-13	37.132660	360.590526	4.989196	7.442613	Si
7	116.442953	81.053767	2018-07-14	35.389186	395.979712	4.989196	7.093163	Si
8	121.318182	79.319840	2018-07-15	41.998342	437.978054	4.989196	8.417857	Si



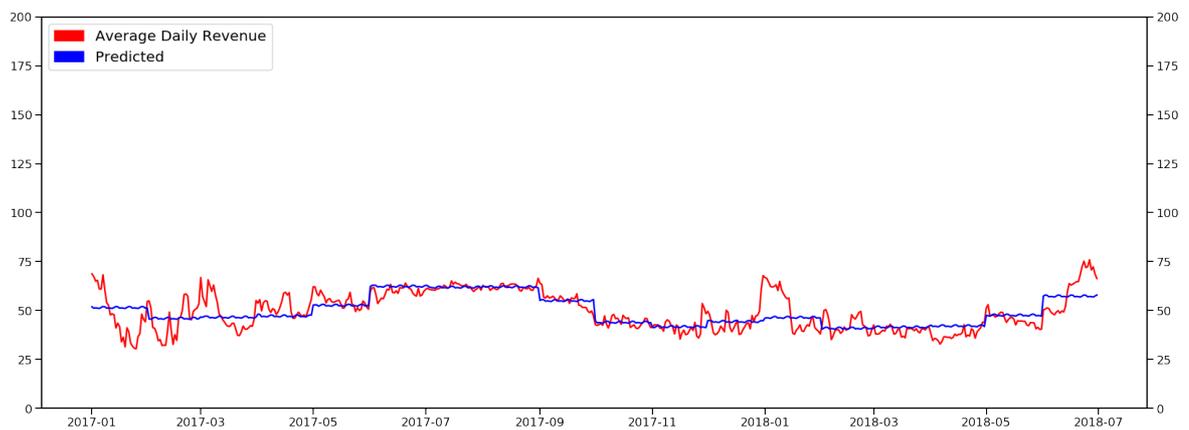
### 6.8.5 Sochi

- Output prodotto

#### OLS Regression Results

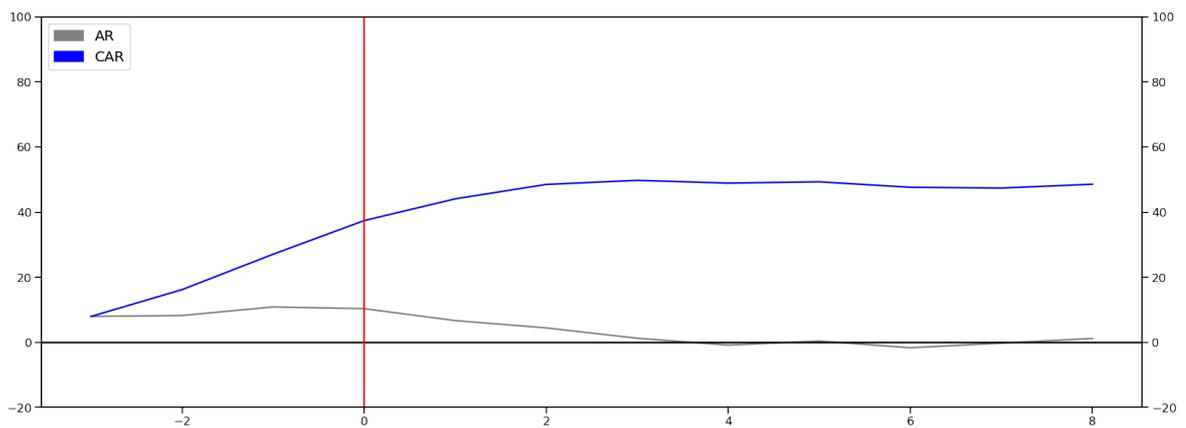
Dep. Variable:	Average Daily Revenue	R-squared:	0.553
Model:	OLS	Adj. R-squared:	0.538
Method:	Least Squares	F-statistic:	79.53
Date:	Sun, 04 Oct 2020	Prob (F-statistic):	3.19e-137
Time:	23:16:41	Log-Likelihood:	-1795.5
No. Observations:	546	AIC:	3629.
Df Residuals:	527	BIC:	3711.
Df Model:	18		
Covariance Type:	HAC		

	coef	std err	t	P> t	[0.025	0.975]
const	46.3776	2.428	19.099	0.000	41.607	51.148
Trend	-0.4203	0.157	-2.674	0.008	-0.729	-0.112
gen	5.0748	4.210	1.205	0.229	-3.195	13.345
mar	0.9903	2.534	0.391	0.696	-3.987	5.968
apr	2.0229	2.444	0.828	0.408	-2.779	6.825
mag	7.9238	2.067	3.834	0.000	3.864	11.984
giu	18.0737	2.853	6.336	0.000	12.470	23.678
lug	17.9969	1.898	9.484	0.000	14.269	21.725
ago	18.6213	1.831	10.172	0.000	15.025	22.217
set	12.0094	2.197	5.466	0.000	7.693	16.326
ott	1.3545	1.840	0.736	0.462	-2.259	4.968
nov	-0.4846	2.011	-0.241	0.810	-4.435	3.466
dic	2.5632	2.520	1.017	0.309	-2.386	7.513
lun	1.0222	0.540	1.892	0.059	-0.039	2.084
mer	0.5434	0.470	1.157	0.248	-0.379	1.466
gio	0.2051	0.509	0.403	0.687	-0.795	1.206
ven	0.3295	0.587	0.561	0.575	-0.825	1.483
sab	0.1490	0.636	0.234	0.815	-1.100	1.398
dom	0.8974	0.658	1.363	0.173	-0.396	2.190



- AR, CAR, T-Test e andamento AR-CAR

Period	Average Daily Revenue	Predicted	Date	AR	CAR	STD AR	T-Test AR	Significant
-3	64.538126	56.594205	2018-07-04	7.943921	7.943921	4.574817	1.736446	None
-2	64.627530	56.389064	2018-07-05	8.238466	16.182387	4.574817	1.800830	None
-1	67.795681	56.932431	2018-07-06	10.863251	27.045637	4.574817	2.374576	Si
0	67.744479	57.411241	2018-07-07	10.333239	37.378876	4.574817	2.258722	Si
1	63.963370	57.286503	2018-07-08	6.676867	44.055743	4.574817	1.459483	None
2	60.969880	56.538055	2018-07-09	4.431825	48.487568	4.574817	0.968744	None
3	57.973856	56.718527	2018-07-10	1.255329	49.742897	4.574817	0.274400	None
4	55.739785	56.594205	2018-07-11	-0.854420	48.888476	4.574817	-0.186766	None
5	56.790497	56.389064	2018-07-12	0.401432	49.289909	4.574817	0.087748	None
6	55.262605	56.932431	2018-07-13	-1.669825	47.620083	4.574817	-0.365004	None
7	57.167715	57.411241	2018-07-14	-0.243526	47.376557	4.574817	-0.053232	None
8	58.465839	57.286503	2018-07-15	1.179336	48.555893	4.574817	0.257789	None



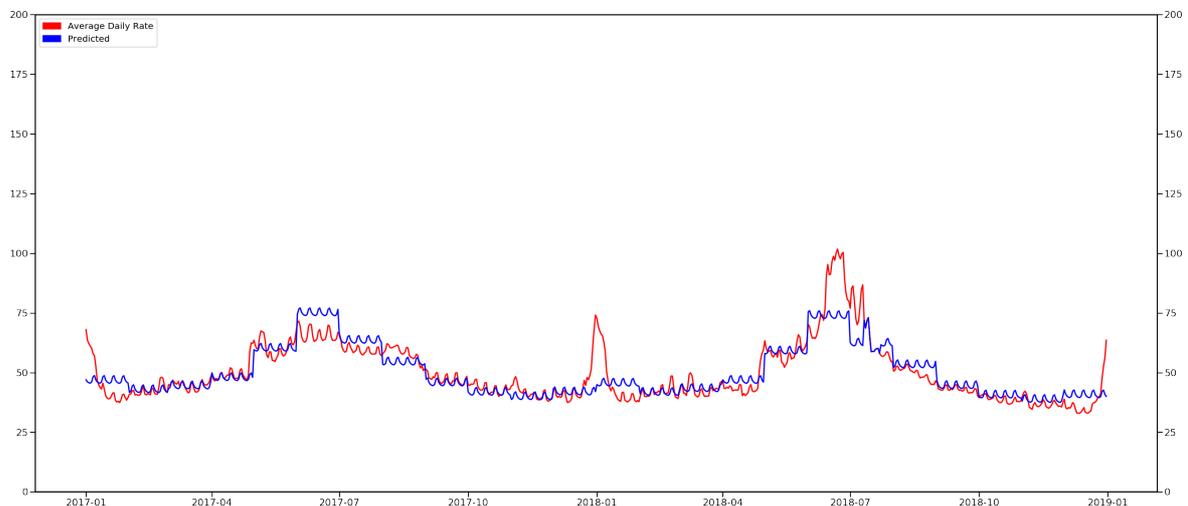
## 6.9 Alternative Trend and Seasonality Model

### 6.9.1 San Pietroburgo

#### OLS Regression Results

Dep. Variable:	Average Daily Rate	R-squared:	0.729
Model:	OLS	Adj. R-squared:	0.718
Method:	Least Squares	F-statistic:	1.721e+05
Date:	Tue, 06 Oct 2020	Prob (F-statistic):	0.00
Time:	20:23:27	Log-Likelihood:	-2387.8
No. Observations:	730	AIC:	4838.
Df Residuals:	699	BIC:	4980.
Df Model:	30		
Covariance Type:	HAC		

	coef	std err	t	P> t	[0.025	0.975]
const	42.2545	0.931	45.388	0.000	40.427	44.082
Trend	-0.0032	0.003	-0.996	0.320	-0.009	0.003
gen	3.8070	3.062	1.243	0.214	-2.204	9.818
feb	2.767e-14	1.2e-14	2.311	0.021	4.16e-15	5.12e-14
mar	1.6843	0.628	2.682	0.007	0.451	2.917
apr	5.2250	1.258	4.154	0.000	2.755	7.695
mag	17.6508	1.038	17.009	0.000	15.613	19.688
giu	32.6162	4.391	7.429	0.000	23.996	41.237
lug	21.1661	2.853	7.419	0.000	15.565	26.768
ago	12.1786	1.645	7.406	0.000	8.950	15.407
set	3.5271	1.005	3.509	0.000	1.554	5.501
ott	-0.3131	1.132	-0.277	0.782	-2.536	1.909
nov	-2.0715	1.272	-1.628	0.104	-4.570	0.427
dic	-0.0058	2.290	-0.003	0.998	-4.502	4.490
lun	2.6798	0.408	6.568	0.000	1.879	3.481
mer	2.1557	0.326	6.616	0.000	1.516	2.795
gio	-0.5270	0.330	-1.596	0.111	-1.175	0.121
ven	-0.3732	0.476	-0.784	0.433	-1.308	0.562
sab	0.0192	0.528	0.036	0.971	-1.016	1.055
dom	0.8785	0.493	1.781	0.075	-0.090	1.847
Event -3	10.7242	3.241	3.309	0.001	4.360	17.088
Event -2	6.9696	3.188	2.186	0.029	0.711	13.229
Event -1	7.9016	3.145	2.513	0.012	1.727	14.076
Event 0	8.6390	3.125	2.764	0.006	2.503	14.775
Event 1	2.4742	3.221	0.768	0.443	-3.849	8.798
Event 2	-2.9210	3.324	-0.879	0.380	-9.447	3.605
Event 3	-2.4402	3.374	-0.723	0.470	-9.064	4.184
Event 4	-2.3248	3.253	-0.715	0.475	-8.711	4.061
Event 5	-2.0092	3.199	-0.628	0.530	-8.291	4.272
Event 6	-3.7683	3.156	-1.194	0.233	-9.965	2.429
Event 7	-4.2174	3.137	-1.345	0.179	-10.376	1.941
Event 8	-4.4705	3.232	-1.383	0.167	-10.817	1.876

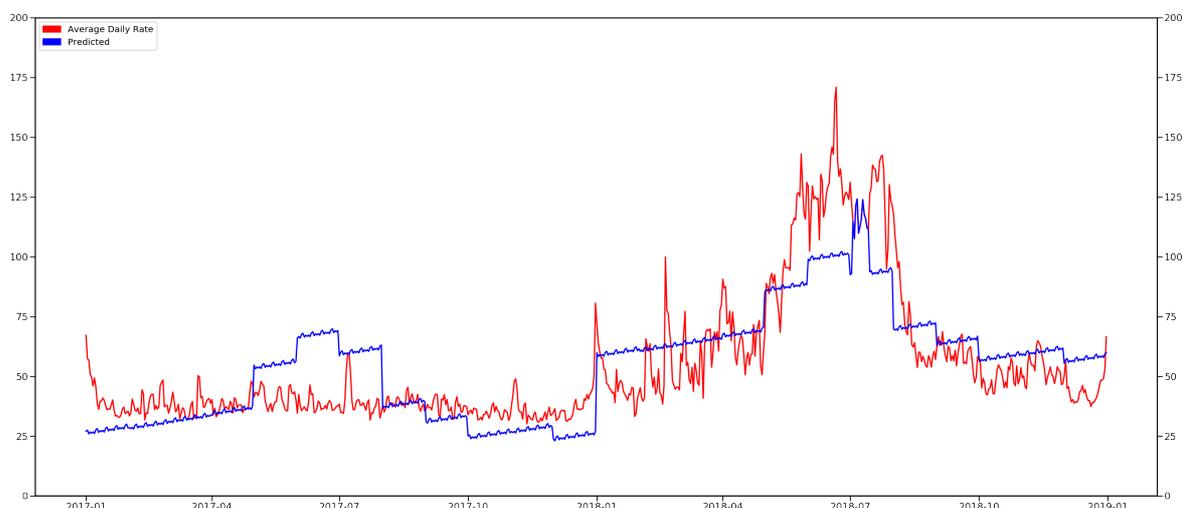


## 6.9.2 Nizhnij Novgorod

### OLS Regression Results

Dep. Variable:	Average Daily Rate	R-squared:	0.649
Model:	OLS	Adj. R-squared:	0.634
Method:	Least Squares	F-statistic:	225.3
Date:	Tue, 06 Oct 2020	Prob (F-statistic):	1.07e-282
Time:	20:09:24	Log-Likelihood:	-3079.3
No. Observations:	730	AIC:	6221.
Df Residuals:	699	BIC:	6363.
Df Model:	30		
Covariance Type:	HAC		

	coef	std err	t	P> t	[0.025	0.975]
const	25.1685	3.986	6.314	0.000	17.343	32.994
Trend	0.0889	0.009	9.942	0.000	0.071	0.106
gen	0.6159	5.942	0.104	0.917	-11.051	12.283
mar	0.1592	4.081	0.039	0.969	-7.853	8.172
apr	0.7341	4.057	0.181	0.856	-7.231	8.700
mag	17.2592	7.007	2.463	0.014	3.501	31.017
giu	27.4219	11.365	2.413	0.016	5.108	49.736
lug	17.5511	10.537	1.666	0.096	-3.137	38.239
ago	-7.2773	5.157	-1.411	0.159	-17.403	2.849
set	-16.2139	4.512	-3.594	0.000	-25.072	-7.356
ott	-25.6536	5.200	-4.934	0.000	-35.862	-15.445
nov	-25.9010	5.158	-5.022	0.000	-36.028	-15.774
dic	-31.6710	6.544	-4.840	0.000	-44.518	-18.824
lun	-0.3183	1.198	-0.266	0.791	-2.670	2.033
mer	0.4635	1.025	0.452	0.651	-1.548	2.475
gio	0.5607	0.946	0.592	0.554	-1.298	2.419
ven	-0.1333	1.103	-0.121	0.904	-2.299	2.032
sab	1.5531	1.192	1.303	0.193	-0.788	3.894
dom	1.1545	1.309	0.882	0.378	-1.415	3.724
Event -3	23.3089	10.773	2.164	0.031	2.157	44.461
Event -2	15.4119	10.874	1.417	0.157	-5.937	36.761
Event -1	29.7925	10.738	2.774	0.006	8.709	50.876
Event 0	31.9591	10.551	3.029	0.003	11.243	52.675
Event 1	18.3122	10.466	1.750	0.081	-2.236	38.860
Event 2	19.4399	10.671	1.822	0.069	-1.512	40.392
Event 3	22.3929	10.641	2.104	0.036	1.502	43.284
Event 4	31.9496	10.796	2.959	0.003	10.753	53.147
Event 5	25.1906	10.897	2.312	0.021	3.796	46.586
Event 6	23.7689	10.762	2.209	0.028	2.639	44.899
Event 7	19.4171	10.575	1.836	0.067	-1.345	40.179
Event 8	19.1556	10.489	1.826	0.068	-1.438	39.749

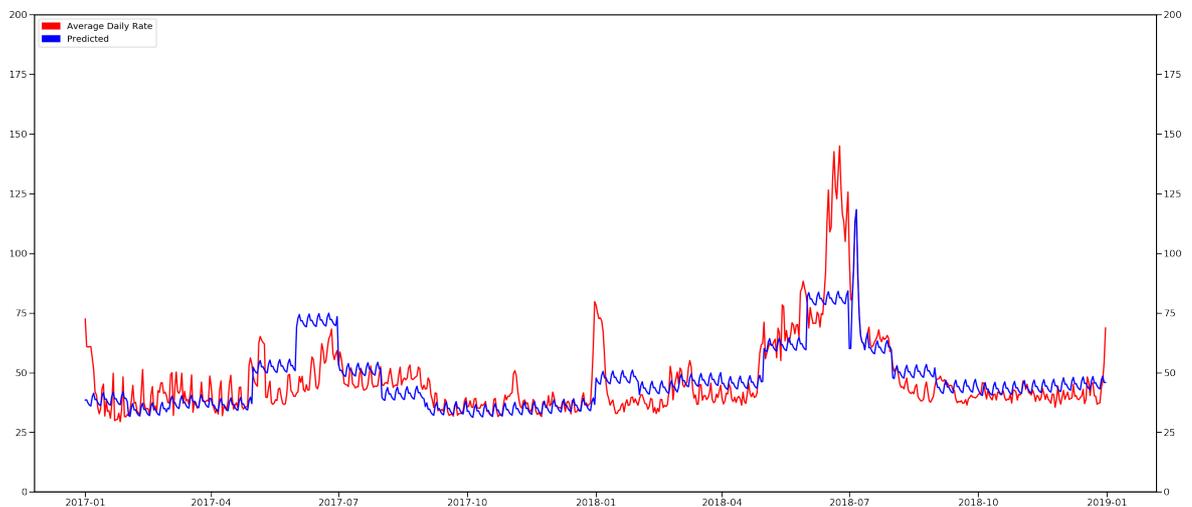


### 6.9.3 Kazan

#### OLS Regression Results

Dep. Variable:	Average Daily Rate	R-squared:	0.583
Model:	OLS	Adj. R-squared:	0.565
Method:	Least Squares	F-statistic:	2.605e+05
Date:	Tue, 06 Oct 2020	Prob (F-statistic):	0.00
Time:	20:29:30	Log-Likelihood:	-2768.2
No. Observations:	730	AIC:	5598.
Df Residuals:	699	BIC:	5741.
Df Model:	30		
Covariance Type:	HAC		

	coef	std err	t	P> t	[0.025	0.975]
const	30.7961	2.280	13.505	0.000	26.319	35.273
Trend	0.0251	0.005	4.587	0.000	0.014	0.036
gen	5.0451	4.313	1.170	0.243	-3.423	13.513
feb	-7.426e-14	4.13e-15	-17.965	0.000	-8.24e-14	-6.61e-14
mar	2.4066	2.366	1.017	0.310	-2.240	7.053
apr	0.5840	2.484	0.235	0.814	-4.293	5.461
mag	15.7707	3.738	4.219	0.000	8.432	23.110
giu	34.3467	9.094	3.777	0.000	16.492	52.201
lug	12.8823	2.682	4.803	0.000	7.617	18.148
ago	2.1367	3.249	0.658	0.511	-4.242	8.516
set	-4.9739	2.625	-1.895	0.059	-10.127	0.180
ott	-6.5468	2.479	-2.641	0.008	-11.414	-1.680
nov	-6.3505	2.867	-2.215	0.027	-11.980	-0.721
dic	-5.9103	2.948	-2.005	0.045	-11.697	-0.123
lun	5.3373	0.893	5.974	0.000	3.583	7.091
mer	3.7677	0.670	5.622	0.000	2.452	5.083
gio	0.3907	0.596	0.656	0.512	-0.779	1.561
ven	1.2727	0.707	1.800	0.072	-0.116	2.661
sab	2.6585	0.811	3.278	0.001	1.066	4.251
dom	2.5987	0.921	2.820	0.005	0.790	4.408
Event -3	21.6238	2.350	9.200	0.000	17.009	26.238
Event -2	35.6508	2.429	14.674	0.000	30.881	40.421
Event -1	55.5483	2.343	23.711	0.000	50.949	60.148
Event 0	56.9621	2.381	23.920	0.000	52.287	61.638
Event 1	28.5141	2.547	11.194	0.000	23.513	33.515
Event 2	14.1014	2.535	5.563	0.000	9.125	19.078
Event 3	5.2380	2.370	2.210	0.027	0.584	9.892
Event 4	3.9131	2.374	1.648	0.100	-0.748	8.575
Event 5	4.2025	2.453	1.713	0.087	-0.614	9.019
Event 6	1.8879	2.365	0.798	0.425	-2.755	6.531
Event 7	2.6602	2.402	1.107	0.268	-2.056	7.376
Event 8	3.5376	2.569	1.377	0.169	-1.507	8.582



### 6.9.4 Samara

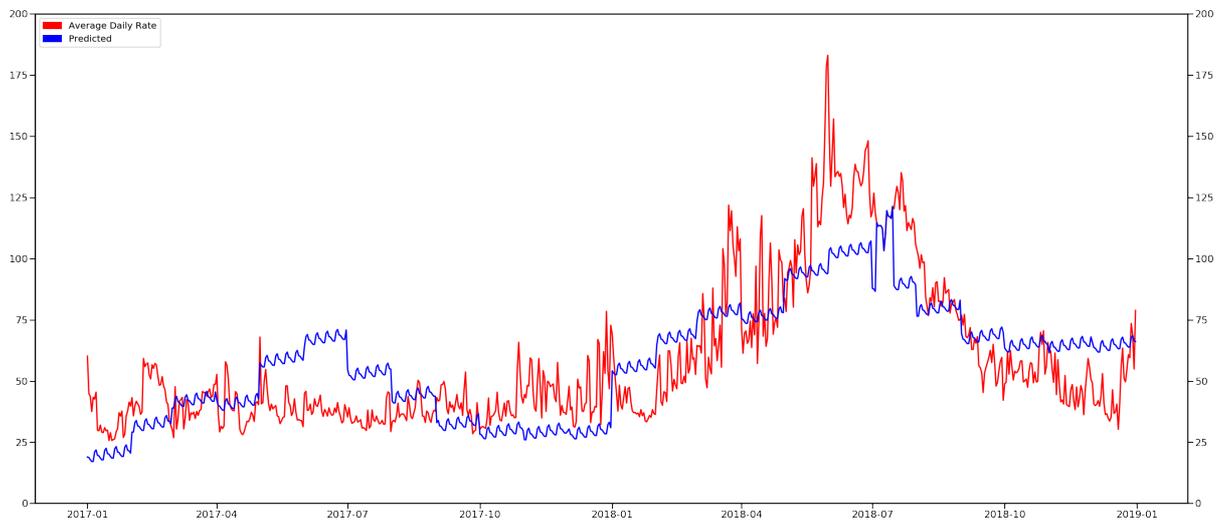
#### OLS Regression Results

```

=====
Dep. Variable: Average Daily Rate    R-squared: 0.608
Model: OLS                          Adj. R-squared: 0.591
Method: Least Squares               F-statistic: 691.7
Date: Tue, 06 Oct 2020              Prob (F-statistic): 0.00
Time: 20:17:35                      Log-Likelihood: -3170.7
No. Observations: 730               AIC: 6403.
Df Residuals: 699                   BIC: 6546.
Df Model: 30
Covariance Type: HAC
=====

```

	coef	std err	t	P> t	[0.025	0.975]
const	25.9367	6.248	4.151	0.000	13.670	38.203
Trend	0.0974	0.010	9.827	0.000	0.078	0.117
gen	-9.2920	7.631	-1.218	0.224	-24.275	5.690
feb	2.282e-14	1.09e-14	2.085	0.037	1.33e-15	4.43e-14
mar	7.0973	7.064	1.005	0.315	-6.772	20.967
apr	2.8218	6.116	0.461	0.645	-9.187	14.830
mag	17.7316	9.418	1.883	0.060	-0.759	36.222
giu	23.5432	11.709	2.011	0.045	0.554	46.532
lug	6.3702	10.466	0.609	0.543	-14.178	26.918
ago	-5.8346	6.466	-0.902	0.367	-18.530	6.861
set	-20.4398	6.862	-2.979	0.003	-33.912	-6.968
ott	-26.5555	7.017	-3.784	0.000	-40.333	-12.778
nov	-29.7247	8.828	-3.367	0.001	-47.057	-12.392
dic	-32.7627	9.076	-3.610	0.000	-50.581	-14.944
lun	4.5226	1.563	2.893	0.004	1.453	7.592
mer	3.7203	1.327	2.803	0.005	1.115	6.326
gio	0.0797	1.234	0.065	0.949	-2.343	2.502
ven	0.8686	1.342	0.647	0.518	-1.766	3.503
sab	1.8834	1.513	1.245	0.214	-1.087	4.854
dom	2.2151	1.622	1.366	0.172	-0.969	5.399
Event -3	28.7457	9.598	2.995	0.003	9.901	47.591
Event -2	27.2297	9.619	2.831	0.005	8.344	46.115
Event -1	23.7492	9.446	2.514	0.012	5.204	42.295
Event 0	22.7091	9.394	2.418	0.016	4.266	41.152
Event 1	23.6917	9.443	2.509	0.012	5.152	42.231
Event 2	14.9876	9.402	1.594	0.111	-3.471	33.446
Event 3	22.0802	9.460	2.334	0.020	3.506	40.654
Event 4	32.9553	9.624	3.424	0.001	14.060	51.851
Event 5	30.6898	9.645	3.182	0.002	11.753	49.626
Event 6	26.7029	9.470	2.820	0.005	8.110	45.296
Event 7	25.0844	9.417	2.664	0.008	6.595	43.574
Event 8	32.1698	9.469	3.397	0.001	13.579	50.761



## 6.9.5 Sochi

### OLS Regression Results

```

=====
Dep. Variable:   Average Daily Rate   R-squared:           0.636
Model:          OLS                   Adj. R-squared:      0.621
Method:         Least Squares         F-statistic:         3.789e+04
Date:           Tue, 06 Oct 2020      Prob (F-statistic):  0.00
Time:           20:23:16              Log-Likelihood:      -2347.6
No. Observations: 730                AIC:                 4757.
Df Residuals:   699                  BIC:                 4900.
Df Model:       30
Covariance Type: HAC
=====

```

	coef	std err	t	P> t	[0.025	0.975]
const	47.1135	2.185	21.560	0.000	42.823	51.404
Trend	-0.0178	0.003	-6.224	0.000	-0.023	-0.012
gen	4.9680	4.321	1.150	0.251	-3.515	13.451
feb	-1.564e-15	2.26e-15	-0.693	0.489	-6e-15	2.87e-15
mar	1.1148	2.591	0.430	0.667	-3.972	6.202
apr	2.2640	2.417	0.937	0.349	-2.482	7.010
mag	8.2905	2.107	3.934	0.000	4.153	12.428
giu	18.5582	3.132	5.926	0.000	12.410	24.707
lug	18.9784	1.984	9.566	0.000	15.083	22.874
ago	16.4277	2.066	7.953	0.000	12.372	20.483
set	10.0011	2.164	4.621	0.000	5.752	14.250
ott	2.4458	2.001	1.222	0.222	-1.483	6.375
nov	0.5139	2.164	0.237	0.812	-3.735	4.763
dic	0.8221	2.513	0.327	0.744	-4.112	5.756
lun	0.8750	0.440	1.988	0.047	0.011	1.739
mer	0.5092	0.374	1.360	0.174	-0.226	1.244
gio	0.1464	0.402	0.364	0.716	-0.643	0.936
ven	0.2414	0.464	0.520	0.603	-0.670	1.152
sab	0.2703	0.523	0.517	0.605	-0.757	1.297
dom	0.7892	0.538	1.465	0.143	-0.268	1.846
Event -3	8.0771	0.916	8.814	0.000	6.278	9.876
Event -2	8.3307	0.960	8.677	0.000	6.446	10.216
Event -1	11.0075	0.976	11.281	0.000	9.092	12.923
Event 0	10.6082	0.988	10.741	0.000	8.669	12.547
Event 1	6.9307	0.977	7.093	0.000	5.012	8.849
Event 2	4.4738	0.946	4.727	0.000	2.616	6.332
Event 3	1.5245	0.954	1.598	0.110	-0.348	3.397
Event 4	-0.5968	0.929	-0.642	0.521	-2.422	1.228
Event 5	0.6181	0.974	0.635	0.526	-1.294	2.530
Event 6	-1.4012	0.990	-1.415	0.157	-3.345	0.543
Event 7	0.1558	1.002	0.155	0.876	-1.812	2.124
Event 8	1.5576	0.992	1.571	0.117	-0.389	3.505

