

2018

# Time series for incidences, orders and invoicing forecast

Daniel Tomás

*ISEG Universidade de Lisboa*, danieltomás95@gmail.com

Carlos J. Costa

*Advance/CSG, ISEG Universidade de Lisboa*, cjcosta@iseg.ulisboa.pt

José Pedro Gaivão

*ISEG Universidade de Lisboa*, jpgaivao@iseg.ulisboa.pt

João Paulo Carvalho

*Quidgest*, jpc@quidgest.com

Follow this and additional works at: <https://aisel.aisnet.org/capsi2018>

---

## Recommended Citation

Tomás, Daniel; Costa, Carlos J.; Gaivão, José Pedro; and Carvalho, João Paulo, "Time series for incidences, orders and invoicing forecast" (2018). *2018 Proceedings*. 36.

<https://aisel.aisnet.org/capsi2018/36>

This material is brought to you by the Portugal (CAPSI) at AIS Electronic Library (AISeL). It has been accepted for inclusion in 2018 Proceedings by an authorized administrator of AIS Electronic Library (AISeL). For more information, please contact [elibrary@aisnet.org](mailto:elibrary@aisnet.org).

# Séries temporais para a previsão de incidentes, encomendas e faturação

## *Time series for incidences, orders and invoicing forecast*

Daniel Tomás, ISEG Universidade de Lisboa, Portugal, danieltomás95@gmail.com

Carlos J. Costa, Advance/CSG, ISEG Universidade de Lisboa, Portugal, cjcosta@iseg.ulisboa.pt

José Pedro Gaivão, ISEG Universidade de Lisboa, Portugal, jpgaivao@iseg.ulisboa.pt

João Paulo Carvalho, Quidgest, Portugal, jpc@quidgest.com

### Resumo

A utilização de estudo de séries para previsão é particularmente relevante. A sua utilização em contexto empresarial permite de alguma forma ajustar a estratégia do negócio. Neste contexto, o trabalho reportado neste artigo resultou de um estudo concreto em que se procurou identificar qual a melhor forma de prever recorrendo a vários métodos clássicos no contexto da econometria. Os resultados apresentados demonstram haver diferenças significativas em função das realidades analisadas. Os erros de previsão associados a incidentes são menores do que nas encomendas ou na faturação. Um dos resultados relevantes do trabalho aqui apresentado foi a criação de uma solução que pode ser utilizada por gestores para tomada de decisão.

**Palavras-chave:** previsão; series temporais; bases de dados; ARIMA

### Abstract

*The use of series study for forecasting is particularly relevant. Its use in a business context can somehow adjust the business strategy. In this context, the work reported in this article corresponds to an empirical study in which the best way to predict using several classical methods in the context of econometrics was identified. The results presented show significant differences in function of the analysed realities. Forecast errors associated with incidents are less than orders or invoicing. One of the relevant results of the work presented here was the creation of a solution that can be used by managers for decision making.*

**Keywords:** prediction; time series; databases; ARIMA

## 1. INTRODUÇÃO

A conjuntura empresarial obriga as empresas a ser cada vez mais competitivas. Os mercados são cada vez mais exigentes, sendo imprescindível antecipar tendências. Mas mais que tendências é indispensável prever cada vez com maior precisão. Tem que se prever procura, encomendas, vendas, custos de matérias-primas ou de equipamentos. A utilização de métodos de previsão é cada vez mais utilizada pelas empresas. Com efeito, a sua utilização permite às empresas definirem estratégias para aumentarem as suas vendas e identificar potenciais clientes. Neste contexto, procura-se perceber quais as ferramentas mais indicadas para previsão de faturação, encomendas e incidentes.

Os estudos das séries temporais passam pela identificação das principais características de coleção de observações feitas sequencialmente ao longo do tempo relacionadas com determinadas realidades. No trabalho aqui apresentado, foram utilizados os seguintes modelos para estudo das séries temporais em estudo: Modelos ARIMA (*Auto-Regressive Integrated Moving Average*), Alisamentos Exponenciais, Holt-Winters e Regressões Lineares.

Este artigo, depois de uma breve introdução, apresenta a revisão da literatura. Em seguida é descrito o método utilizado. Depois, os resultados são apresentados, sendo, por fim, realizada uma breve discussão e conclusão.

## 2. REVISÃO DE LITERATURA

Os métodos modernos para previsão usando séries temporais têm como ideia fundamental que o passado permite de alguma forma antever o futuro. Portanto, a questão de fundo da previsão está relacionada com a forma como se interpreta a informação codificada em eventos passados e o método de extrapolação dessa informação para o futuro.

Os desenvolvimentos teóricos na análise de séries temporais começaram com o advento dos processos estocásticos. A abordagem clássica à previsão usando séries temporais é baseada na regressão. O modelo standard de regressão envolve a especificação de uma relação paramétrica entre um conjunto de variáveis explanatórias (ou exógenas) e um conjunto de variáveis dependentes (ou endógenas). A estimação dos parâmetros do modelo pode ser realizada de diversas maneiras, com origem no trabalho pioneiro de Gauss em 1794 com o método dos mínimos quadrados.

A primeira aplicação real de modelos autorregressivos para previsão remonta ao trabalho de G. U Yule (Yule, 1927) e J. Walker (Walker, 1931) nas décadas de 1920 e 1930. Durante esse período, a média móvel foi introduzida para remover flutuações periódicas nas séries temporais, por exemplo, flutuações devido à sazonalidade. Herman Wold (1954) introduziu os modelos ARMA (*Auto-Regressive Moving Average*) para séries estacionárias, mas não conseguiu derivar uma função de verossimilhança para permitir a estimação da máxima verossimilhança (ML) dos parâmetros. Foi só em 1970, que Box e Jenkins (1970) apresentaram o procedimento completo de modelação para séries individuais: especificação, estimativa, diagnóstico e previsão. Atualmente, os chamados modelos de Box-Jenkins são talvez os mais usados e muitas técnicas usadas para previsão e ajuste sazonal podem ser rastreadas até esses modelos. Ao introduzir diferenciação nas variáveis dependentes, resolvendo assim o problema da estacionariedade da série, obtemos um modelo ARIMA sem sazonalidade (Box & Jenkins, 1970). ARIMA é o acrónimo de *Auto Regressive Integrated Moving Average* e o modelo pode ser escrito da seguinte forma:

$$y'_t = c + \phi_1 y'_{t-1} + \dots + \phi_p y'_{t-p} + \theta_1 \varepsilon_{t-1} + \dots + \theta_q \varepsilon_{t-q} + \varepsilon_t,$$

Chamamos a este modelo ARIMA(p,d,q), com o p a corresponder à ordem da parte autorregressiva, d à ordem de diferenciação e q à ordem da parte médias móveis.

As técnicas desenvolvidas por Box & Jenkins nos anos 70 tiveram um grande sucesso e impacto, em parte devido a uma metodologia simples e de fácil aplicação para a previsão em diversos contextos académicos ou empresariais. Contudo, outros autores preferiam uma abordagem mais estrutural à previsão. Por exemplo, (Harrison & Stevens, 1976) tiveram algum sucesso na formulação de um modelo linear Markoviano num contexto da estatística Bayesiana. Usando o filtro de Kalman, Harrison & Stevens especificaram um modelo linear dinâmico com parâmetros que variam no tempo para resolver o problema da não-estacionariedade.

Uma generalização dos modelos autorregressivos é o chamado ARCH, acrónimo de *autoregressive conditional heteroscedasticity*. Estes modelos foram introduzidos por (Engle, 1982) com o objetivo de capturar a não-estacionariedade do momento de segunda ordem, ou seja, a variância condicional ou volatilidade. Posteriormente, o modelo GARCH (*generalized autoregressive conditional heteroscedasticity*), desenvolvido por (Bollerslev, 1986), representa a variância dos erros como função dos termos autorregressivos.

Outra generalização dos modelos autorregressivos foi aceitar modelos multivariados, entre os quais os modelos VAR (*Vector Autoregressive*) que se tornaram populares. VAR são modelos lineares multivariáveis capazes de capturar a dinâmica conjunta de múltiplas séries temporais. No seu trabalho pioneiro, Sims (1980) propôs a substituição de modelos macroeconómicos de larga escala nos anos 60 por VAR. Estas técnicas são aplicáveis somente para séries temporais estacionárias. No entanto, as séries temporais, nomeadamente as séries de interesse para a Economia, exibem uma tendência crescente sugerindo não-estacionariedade, isto é, a presença de uma raiz unitária.

Os modelos de Alisamento Exponencial surgiram nos finais dos anos 50 e permitiram criar melhores modelos de previsão – Brown (1956). Holt, (1957). Winters (1960).). Este modelo produz pesos médios ponderados das observações passadas, com os pesos a decaírem exponencialmente à medida que a série se torna mais antiga, ou seja, quanto mais recentes são as observações maior será o seu peso para influenciar a previsão. Este tipo de modelo permite prever uma grande variedade de séries temporais e rapidamente, o que se torna uma vantagem para o mercado empresarial nos dias de hoje. No caso multivariado, verificou-se que as séries temporais não estacionárias podem ter uma raiz unitária comum. Estas séries temporais são chamadas de séries temporais co-integradas e podem ser usadas nos chamados modelos de correção de erros dentro de relacionamentos de longo prazo e dinâmicas de curto prazo são estimadas. Os modelos de Regressão linear para séries temporais são modelos de Regressão linear comuns, mas as variáveis dependentes são a sazonalidade e a tendência da série.

Outra classe de modelos, os TAR (threshold nonlinear ARMA), propostos por (Tong, 1990), foram aplicados com sucesso à previsão de variáveis relevantes em Economia. Decompondo séries temporais usando wavelets, (Lineesh & John, 2010) usaram os modelos ARMA e TAR para fazer previsão de cada componente da decomposição. Em Krishnamurthy e Yin (2002), combinaram-se cadeias de Markov ocultas com modelos AR onde os parâmetros do modelo AR variavam de acordo com a realização da cadeia de Markov.

Nas últimas décadas, a previsão usando redes neuronais tem obtido bastante popularidade, devido ao seu desempenho e capacidade de classificação (Zhang, 2012). As redes neuronais têm diversas características únicas que as tornam apelativas: 1) são data-driven; 2) não requerem um modelo explícito subjacente; 3) flexíveis, universais e capazes de lidar com modelos complexos.

No que diz respeito a aplicações práticas, tem havido aplicações desde os modelos financeiros (Khairalla, & Ning.,2017), a telecomunicações (Puente, Hernandez & Salcedo, 2009).). Porém, com frequência, utilizam-se abordagens híbridas (Pati & Shukla, 2015) ou com recurso a redes neuronais (Ji, Yu, Guo, & Zhang, 2016).

### **3. DESCRIÇÃO DO MÉTODO**

#### **3.1. Extração de dados**

As análises e previsões de séries temporais foram realizadas numa empresa multinacional de origem portuguesa, de consultoria e desenvolvimento de sistemas de informação de gestão, que aposta na investigação em engenharia para geração automática de software.

A extração dos dados foi feita através do *SQL Server*, que é o sistema de gestão de bases de dados relacional que a empresa usa. O tratamento dos dados passou por remover os valores nulos e linhas com dados incompletos através da linguagem e ambiente de desenvolvimento R (permite realizar análises de dados e estatísticas), integrado no *SQL Server* através do *R Services*. Em seguida, somar mensalmente a quantidade ou valor desde janeiro de 2010 até dezembro de 2017. Foram criadas três séries – N° de incidentes mensais, faturação mensal (em €), valor mensal de encomendas (em €), transformando os dados de formato *data.frame* para TS (serie temporal), objeto esse que fica com as datas e valores agregados, simplificando a tarefa do R.

As três séries consideradas foram: faturação, encomendas e incidentes. Na faturação, cada linha corresponde ao valor total faturado pela empresa aos seus clientes. Valor total das encomendas entradas no sistema a pedido dos clientes. Um incidente corresponde a qualquer pedido registado na ferramenta de tickets da empresa. Número de observações: 96 meses (8 anos).

Nome da série	Descrição	Valores
Faturação	Faturação mensal em €	12 332 € a 1 640 869 €
Encomendas	Valor de encomendas mensais em €	8 992 € a 4 969 474 €
Incidentes	Nº de incidentes mensais	20 a 514

Tabela 1. Descrição das séries

### 3.2. Tratamento de Dados

Os dados fornecidos pela empresa encontravam-se armazenados no *SQL Server*, foram extraídos inicialmente para o R, através do package *RODBC*, que permite executar *queries* SQL no ambiente R e numa fase posterior esses dados passaram a ser tratados no *SQL Server* com a integração do R. Após se ter configurado a integração, procedeu-se à criação de *stored procedures* que podem conter gráficos, tabelas, sumários e outros elementos, depois usados para a criação de *Reports*.

Foi realizada um estudo sobre métodos de previsão com R, especialmente em séries temporais, referindo alguns dos seus métodos e modelos previsionais (Hyndman & Athanasopoulos, 2012). Os *Reports* foram desenvolvidos em *Visual Studio* através da extensão de *Reporting Services* do *SQL Server*, têm um campo para selecionar o número de meses que o utilizador pretende prever, menus com os possíveis modelos de previsão disponíveis, contêm uma breve explicação do modelo, gráfico com a previsão, sumário dos dados e erros de previsão, tudo isto desenvolvido com funções do R que geram estas previsões de forma automática, selecionando a melhor possibilidade para cada modelo. Foram desenvolvidos *Reports* para fazer previsões para faturação, número de incidentes e encomendas.

Para realizar previsões foram escolhidos os modelos – ARIMA, Alisamentos Exponenciais (*Holt Winters* incluído) e Regressão Linear com variáveis explicativas sazonalidade e tendência. Estes modelos foram os modelos escolhidos por terem sido os melhores a prever algumas das séries de teste.

O critério usado para escolher o melhor modelo foi o menor erro absoluto médio em percentagem (MAPE), o qual, para a avaliação modelos de séries temporais é considerado o melhor e por isso é o mais usado (<https://robjhyndman.com/hyndsight/smape/>). No entanto, deixamos à disposição do decisor/gestor um conjunto de erros de previsão diferentes para outro tipo de avaliação do modelo. Para escolher de forma automática o melhor modelo, o R compara o MAPE de todos os modelos e, quando o menor MAPE for encontrado, surge uma mensagem – “Observando os erros absolutos médios em percentagem, é possível concluir que o melhor modelo é o modelo: ...”.

## 4. RESULTADOS

Em primeiro lugar há que considerar que um dos resultados do trabalho empírico se traduziu na produção de *Reports*.

A plataforma escolhida para a criação de *Reports* foi o *Visual Studio*, agregado ao *Reporting Services* do SQL Server. Os *Reports* são automáticos na exibição dos gráficos e tabelas, o utilizador apenas tem que definir o período de tempo que pretende prever.

O utilizador, ao abrir o *Report*, tem uma barra no topo da página que serve como menu, tendo seis opções:

- Série Original, é a opção que vem pré-selecionada quando o utilizador abre o *Report*, contém gráficos da série e decomposição como também um sumário da série;
- Modelo ARIMA, onde se obtêm as previsões e erros de previsão para o Modelo ARIMA;
- Modelo HW, o mesmo que o anterior, mas para o Modelo Holt-Winters;
- Modelo ETS, o mesmo, para o Modelo Alisamento Exponencial;
- Modelo LM, o mesmo para o Modelo de Regressão Linear;
- Previsões, onde surgem os valores de todos os modelos previstos, com a conclusão de qual o melhor modelo.

Nos Modelos será perguntado ao utilizador o número de meses que pretende prever, numa secção do *Report* em cima do menu. Para alterar o número de meses a prever, o utilizador pode alterar o valor e pressionar o botão *View Report*, que se encontra no canto superior direito do *Report*. É possível alternar entre menus, sem perder o que foi selecionado anteriormente, basta selecionar o botão de retroceder. Se o utilizador pretender guardar um modelo do *Report*, tem a opção de o guardar em Word, Excel, PowerPoint, PDF e *Data Feed*, tendo também a possibilidade de o imprimir.

Os Reports foram construídos de forma a serem de fácil compreensão e úteis para os gestores da empresa. Para isso, em cada uma das abas tem uma explicação básica sobre os modelos e não foram considerados testes para a aprovação dos Modelos, dado que as funções automáticas do package forecast garantem na maioria dos casos o melhor modelo possível para a série.

Na aba Série Original, temos um sumário da série com os quartis, mínimo, média e máximo, que dá ao gestor uma ideia inicial de como é o comportamento dos dados, em seguida uma representação gráfica da série e um gráfico com a decomposição da série, com as componentes sazonalidade, tendência e série irregular, que permitem obter informações importantes sobre os comportamentos passados e a encontrar explicações para o porquê desses comportamentos.

Na aba Modelo ARIMA, após a seleção do número de meses a prever, temos uma explicação breve do que é um Modelo ARIMA, gráfico da série com a previsão já incluída e, para além da previsão, contém 2 níveis de intervalos de confiança a 80 e 95% para os valores previstos e, ainda, um *barplot* com os erros de Previsão da Série – ME (erro médio), RMSE( raiz do erro médio), MAE ( erro

absoluto médio), MPE(erro médio em percentagem), MAPE(erro absoluto médio em percentagem) e ACF1 ( Teste de precisão de previsão). Nos restantes Modelos a estrutura é semelhante.

Na aba Previsões, temos uma tabela com a série prevista para os próximos 12 meses com todos os modelos e, em baixo, uma conclusão sobre qual o melhor modelo. O critério para definir qual o melhor modelo nos *Reports* desenvolvidos, é o menor erro absoluto médio em percentagem (MAPE), no entanto, este pode ficar ao critério do gestor, pelo que estão incluídas mais seis opções para além do MAPE.

O *package forecast* fornece 2 tipos de funções para prever Alisamentos exponencias: `ets()` para alisamentos exponenciais de forma geral e `HoltWinters()` para alisamentos exponencias do tipo Holt-Winters. Para criar um modelo com ambas as funções basta inserir no argumento de cada função um objeto do tipo TS. Para a função `ets()` o R seleciona, entre diversos modelos possíveis, o modelo que minimiza os critérios de informação para a série temporal selecionada. Já para a função `Holtwinters()`, o R seleciona, entre diversos modelos possíveis, o modelo que minimiza o erro quadrático médio.

Também foram testados modelos de redes neuronais e *naive method*, mas os resultados não foram satisfatórios. Estes modelos são gerados automaticamente pelas funções do *package forecast*: `auto.arima()`, para os modelos ARIMA; `HoltWinters()`, para os modelos de *Holt-Winters*; `ets()`, para os modelos de Alisamento Exponencial; `tslm()`, para os modelos de Regressão Linear. Para realizar a previsão, basta fazer `forecast(modelo, h=nº de períodos a prever)`. Para criar um gráfico simples, basta introduzir `autoplot(forecast)`.

Na tabela 2, são apresentadas as previsões para a série faturação.

Data	ARIMA	Holt-Winters	Alisamento Exponencial	Regressão Linear
jan/18	109510	149402	102964	110677
fev/18	286983	387130	456034	323346
mar/18	224514	336529	359829	290294
abr/18	173163	243017	214994	198373
mai/18	221552	320676	304486	259635
jun/18	422612	441890	423699	325633
jul/18	337460	389022	288489	265294
ago/18	283667	367434	305334	275736
set/18	527731	597749	641129	449387
out/18	466886	484930	397520	331393
nov/18	602874	615185	526978	448612
dez/18	1068540	1284600	1674240	1200060

Tabela 2. Síntese dos dados da série de faturação



O gráfico da figura 1 apresenta os valores mensais de faturação.

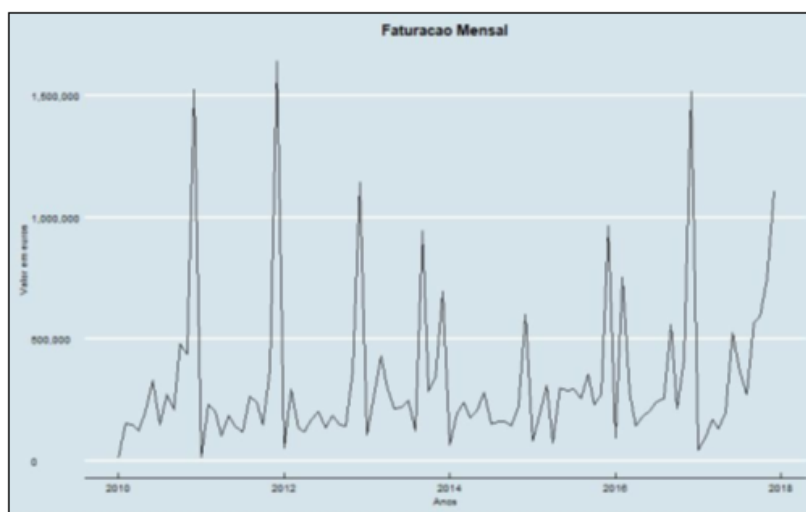


Figura 1 – Faturação mensal

O gráfico da figura 2 mostra a decomposição da faturação mensal, separando sazonalidades e tendências.

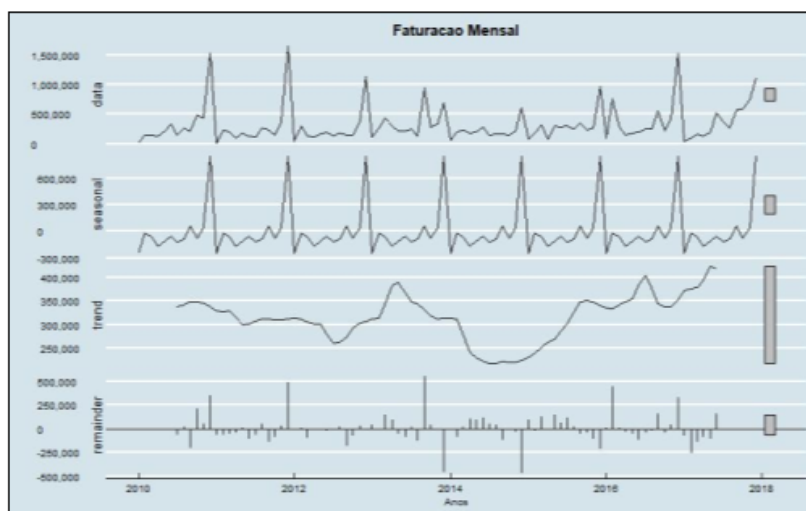


Figura 2 – Decomposição da Série Faturação

O gráfico da figura 3 mostra o modelo de previsão com regressão linear




Figura 3 – Modelo de previsão utilizando regressão linear

A tabela 3 permite comparar os modelos quanto aos erros de previsão, utilizando diversas métricas atrás referidas.

Modelos /Erros de Previsão	ME	RMSE	MAE	MPE	MAPE	ACF1
ARIMA	3312,63	203551,72	126495,9	-49,99	70,1	0,14
Holt-Winters	33232,5	199552	123282	0,9	47,121	0,12
Alisamento Exponencial	6484,58	155154,62	87813,62	-51,77	76,16	0,11
Regressão Linear	0	161415,81	102243,3	-18,58	37,68	0,16

Tabela 3 – Comparação dos Modelos

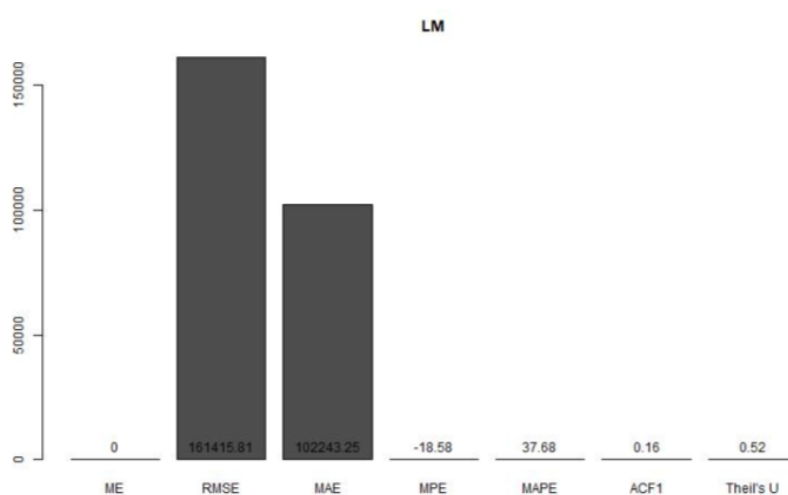


Figura 4 – Erros de previsão

Seguindo o critério de escolha – menor erro médio absoluto em percentagem (MAPE) – chegou-se à conclusão que o modelo que melhor previu a faturação de uma empresa de Consultoras de IT foi o modelo de Regressão Linear com 37,68.

A tabela que se segue apresenta os resultados síntese das previsões das encomendas utilizando os métodos de ARIMA, *Holt-Winters*, alisamento exponencial e regressão linear.

Data	ARIMA	Holt-Winters	Alisamento Exponencial	Regressão Linear
jan/18	369821,8	593005,8	315186,7	450972,0
fev/18	369821,8	517462,7	197221,3	379656,8
mar/18	369821,8	523462,7	545605,6	577443,7
abr/18	369821,8	549955,7	387676,8	429116,4
mai/18	369821,8	559667,9	340927,4	434064,9
jun/18	369821,8	577014,8	621255,0	683522,1
jul/18	369821,8	565807,0	430794,6	415651,7
ago/18	369821,8	589985,6	209251,4	316061,0
set/18	369821,8	669007,1	229238,2	361667,4
out/18	369821,8	596458,7	217387,6	370092,3
nov/18	369821,8	788013,2	672872,8	437032,2
dez/18	369821,8	1120820,9	1472095,1	1095571,8

Tabela 4 – Síntese das previsões das encomendas

A tabela 5 permite comparar os modelos quanto aos erros de previsão, utilizando para tal, métricas referidas atrás.

Modelos /Erros de Previsão	ME	RMSE	MAE	MPE	MAPE	ACF1
ARIMA	69401,97	574714,20	200345,60	-123,99	161,39	-0,07
Alisamento Exponencial	19443,33	521606,60	210694,20	-131,23	161,84	-0,06
Holt-Winters	44785,17	583814,80	249280,50	-98,16	145,36	-0,05
Regressão Linear	0	521404,9	232693,4	-126,99	203,61	-0,08

Tabela 5 – Comparação dos Modelos

Devido à variação elevada dos dados (vários picos em meses com valores baixos em média), não foi possível efetuar uma boa previsão de encomendas. Contudo, seguindo o critério de escolha – menor erro médio absoluto em percentagem (MAPE) – chegou-se à conclusão que o modelo que melhor previu o valor em encomendas de uma empresa de Consultoras de IT foi o modelo Holt-Winters com 145,36. Em trabalhos futuros, seria ideal usar outros modelos ou outras abordagens (sem ser com séries temporais).

A tabela que se segue apresenta os resultados síntese das previsões dos incidentes, utilizando os métodos de ARIMA, Holt-Winters, alisamento exponencial e regressão linear.

Data	ARIMA	Holt-Winters	Alisamento Exponencial	Regressão Linear
jan/18	500	464	496	469
fev/18	465	426	471	471
mar/18	387	379	414	435
abr/18	280	290	380	394
mai/18	344	356	355	386
jun/18	359	342	294	370
jul/18	417	348	302	395
ago/18	349	245	257	347
set/18	412	317	270	394
out/18	312	313	458	434
nov/18	336	340	392	418
dez/18	274	284	293	368

Tabela 6 – Síntese das previsões para os incidentes

A tabela 7 permite comparar os modelos quanto aos erros de previsão, utilizando, para tal, diversas métricas atrás referidas.

Modelos /Erros de Previsão	ME	RMSE	MAE	MPE	MAPE	ACF1
ARIMA	-0,09	65,91	45,89	-8,54	26,58	-0,01
Alisamento Exponencial	-1,16	72,00	48,45	-9,71	29,02	0,20
Holt-Winters	1,95	72,38	52,32	-8,89	31,44	0,10
Regressão Linear	0	80,34	61,06	-18,17	40,04	1,21

Tabela 7. Comparação dos Modelos

Seguindo o critério de escolha – menor erro médio absoluto em percentagem (MAPE) - chegou-se à conclusão que o modelo que melhor previu o nº de incidentes de uma empresa de Consultoria de IT é o modelo de ARIMA com 26,58.

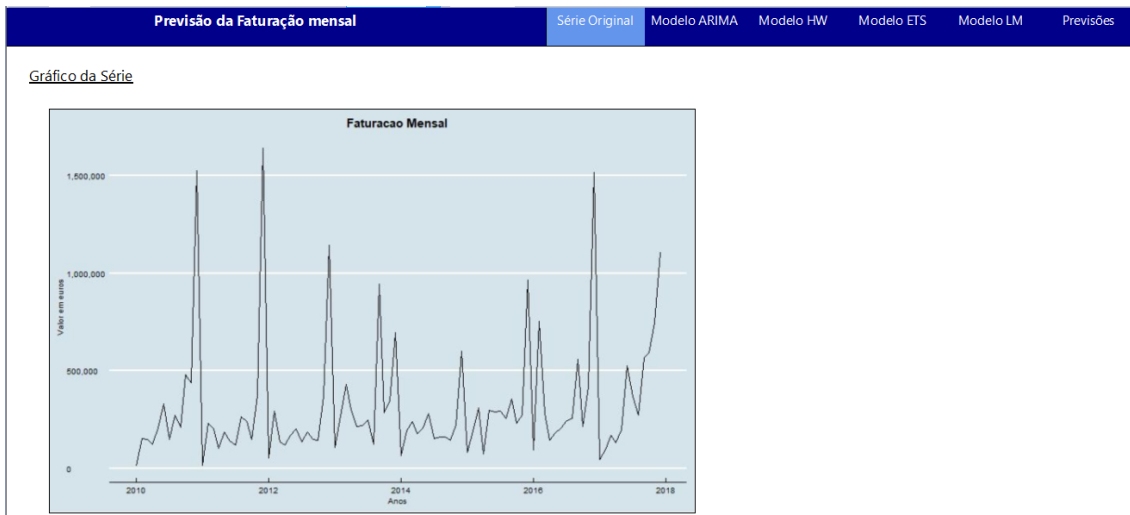


Figura 5 – Layout dos Reports

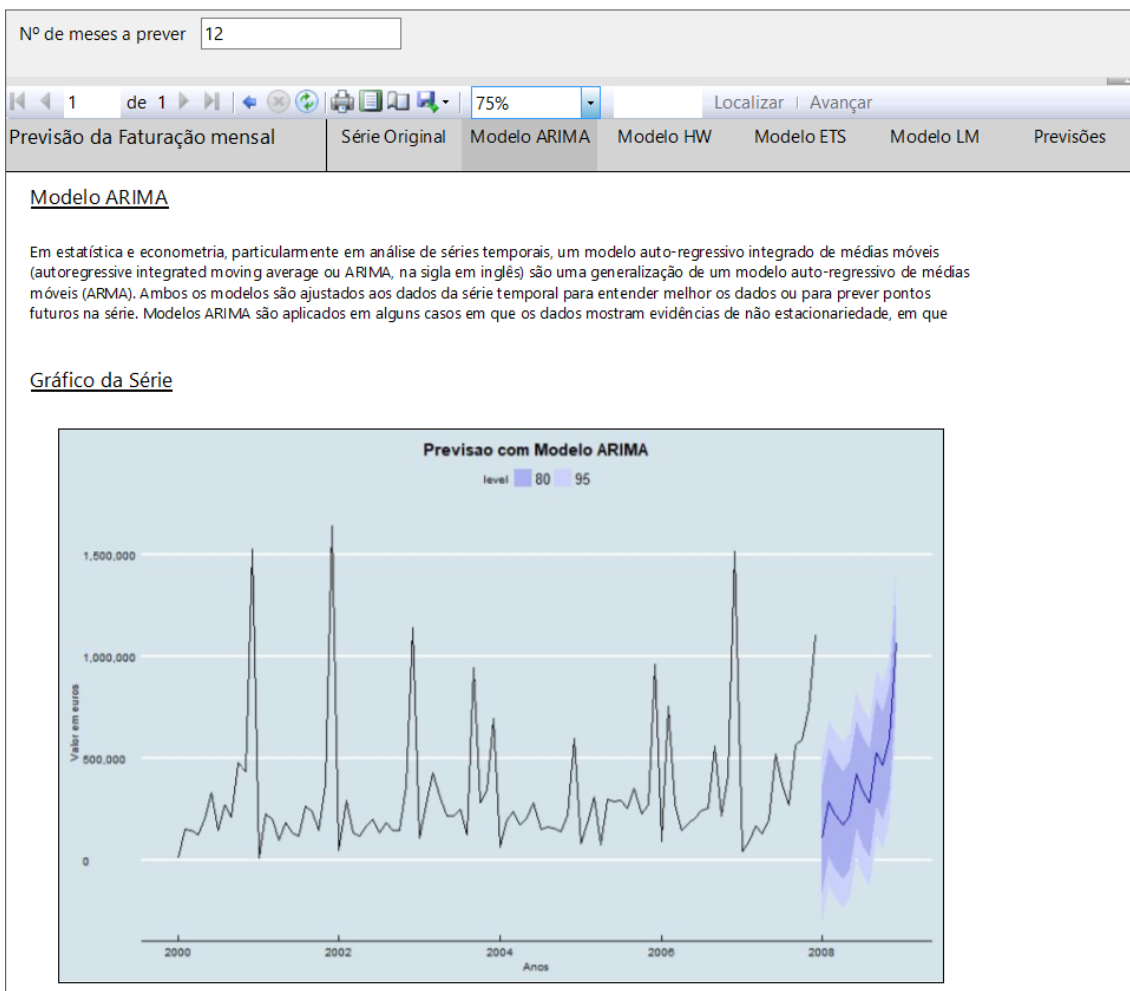


Figura 6 – Layout dos Reports

## 5. DISCUSSÃO E CONCLUSÕES

O estudo de séries para previsão é particularmente relevante. A sua utilização em contexto empresarial permite, de alguma forma, ajustar a estratégia do negócio. Neste contexto, o trabalho reportado neste artigo resultou de um estudo concreto em que se procurou identificar qual a melhor forma de prever recorrendo a vários métodos clássicos no contexto da econometria. Os resultados apresentados demonstram haver diferenças significativas em função das realidades analisadas. Os erros de previsão associados a incidentes são menores do que nas encomendas ou na faturação. Este aspeto poderá decorrer do facto de estas últimas estarem associadas à resposta tática ou operacional.

Um dos resultados relevantes do trabalho realizado foi a produção de *reports*. Estes *reports*, para além de ser importante como suporte ao trabalho empírico, parece ser significativo como complemento ao sistema de *business intelligence*.

Desta forma, a elaboração de metas para a empresa torna-se algo mais realista, motivando os trabalhadores para alcançarem esses objetivos e promovendo a competitividade entre áreas. O marketing é a área que porventura beneficia mais com as previsões, já que, sabendo de antemão os comportamentos sazonais das vendas, pode elaborar ações de marketing de forma mais assertiva.

## AGRADECIMENTOS

Este trabalho é financiado por Fundos Nacionais através da FCT - Fundação para a Ciência e a Tecnologia no âmbito do projeto de financiamento com a Referência UID/SOC/04521/2013.

## Referências

- Bollerslev, T. (1986) Generalized autoregressive conditional heteroskedasticity. *Journal of Econometrics*, 31(3), 307–327.
- Box, G & Jenkins, G (1970). *Time Series Analysis: Forecasting and Control*. San Francisco: Holden-Day.
- Brown, R G. (1956). *Exponential Smoothing for Predicting Demand*. Cambridge, Massachusetts: Arthur D. Little Inc. p. 15.
- Engle, R.F. (1982) Autoregressive conditional heteroscedasticity with estimates of the variance of United Kingdom inflation. *Econometrica*, 50(4), 987–1007.
- Harrison, P.J. & Stevens, C.F. (1976) “Bayesian Forecasting,” *Journal of the Royal Statistical Society Series B*, 38(3), 205-247
- Holt, C. (1957). "Forecasting Trends and Seasonal by Exponentially Weighted Averages". Office of Naval Research Memorandum. 52. reprinted in Holt, Charles C. (January–March 2004). "Forecasting Trends and Seasonal by Exponentially Weighted Averages". *International Journal of Forecasting*. 20 (1): 5–10. doi:10.1016/j.ijforecast.2003.09.015.
- Hyndman, R & Athanasopoulos, G (2012) *Forecasting principles and practice*. Online OpenAccess Text <https://otexts.org/fpp2/>
- Ji, S. Yu, H., Guo, Y. & Zhang, Z. (2016). Research on sales forecasting based on ARIMA and BP neural network combined model. In *Proceedings of the 2016 International Conference on Intelligent Information Processing (ICIIP '16)*. ACM, New York, NY, USA, , Article 41 , 6 pages. DOI: <https://doi.org/10.1145/3028842.3028883>
- Khairalla, MA. & Ning., M. (2017). Financial Time Series Forecasting Using Hybridized Support Vector Machines and ARIMA Models. In *Proceedings of the 2017 International Conference on Wireless Communications, Networking and Applications (WCNA 2017)*, Srikanta Patnaik (Ed.). ACM, New York, NY, USA, 94-98. DOI: <https://doi.org/10.1145/3180496.3180613>

- Krishnamurthy, V. & Yin, G.G. (2002) Recursive algorithms for estimation of hidden Markov models and autoregressive models with Markov regime. *IEEE Transactions on Information Theory*, 48(2), 458–476.
- Lineesh, M.C. & John, C.J. (2010) Analysis of non-stationary time series using wavelet decomposition. *Nature and Science*, 8(1), 53–59.
- Pati, J. & Shukla, K. (2015). A Hybrid Technique for Software Reliability Prediction. In *Proceedings of the 8th India Software Engineering Conference (ISEC '15)*. ACM, New York, NY, USA, 139-146. DOI=<http://dx.doi.org/10.1145/2723742.2723756>
- Puente, F, Hernandez, C. & Salcedo, O. (2009). Comparative analysis of time series techniques ARIMA and ANFIS to forecast Wimax traffic. In *Proceedings of the 7th International Conference on Advances in Mobile Computing and Multimedia (MoMM '09)*. ACM, New York, NY, USA, 277-281. DOI=<http://dx.doi.org/10.1145/1821748.1821801>
- Sims, C. (1980) "Macroeconomics and Reality," *Econometrica*, Vol. 48, No. 1, pp. 1–48, January.
- Tong, H. (1990) *Non-Linear Time Series: A Dynamical System Approach*, Clarendon Press, Oxford, UK.
- Walker, G. (1931) "On Periodicity in Series of Related Terms", *Proceedings of the Royal Society of London, Ser. A*, Vol. 131, 518–532.
- Winters, P. R. (1960). "Forecasting Sales by Exponentially Weighted Moving Averages". *Management Science*. 6 (3): 324–342. doi:10.1287/mnsc.6.3.324.
- Wold, H. (1954) *A Study in the Analysis of Stationary Time Series*, Second revised edition
- Yule, G. (1927) "On a Method of Investigating Periodicities in Disturbed Series, with Special Reference to Wolfer's Sunspot Numbers", *Philosophical Transactions of the Royal Society of London, Ser. A*, Vol. 226, 267–298.]
- Zhang, G. P. (2012) Neural networks for time-series forecasting, in *Handbook of Natural Computing*, Rozenberg, G., Bäck, T. and Kok, J. (eds), Springer, Berlin, Germany, pp. 461–477.