

Previsão de Vendas da Gama de Emergência LED da
ETAP.Schröder

Pedro Filipe Gonçalves Colaço Luís

Projeto de Mestrado Executivo em Direção Comercial

Orientador:

Prof. Doutor José Dias Curto, Prof. Associado, ISCTE Business School
Departamento de Métodos Quantitativos

Co-orientador:

Dr. Miguel Garcia Mamede, SONAE

Maio 2013

AGRADECIMENTOS

À Mafalda, mãe, restante família e amigos, pelo apoio incondicional e pela força que me deram durante o mestrado.

Ao Professor José Dias Curto e ao Dr. Miguel Mamede pela ajuda e paciência que tiveram ao longo deste desafio.

À empresa ETAP.Schröder pela oportunidade concedida para desenvolver este projeto.

ÍNDICE

AGRADECIMENTOS	ii
ÍNDICE DE ILUSTRAÇÕES	v
ÍNDICE DE TABELAS	vi
LISTA DE ABREVIATURAS	vii
RESUMO	1
ABSTRACT	2
SUMÁRIO EXECUTIVO	3
1. INTRODUÇÃO	5
1.1. APRESENTAÇÃO DO PROBLEMA	5
1.2. OBJETIVOS	6
1.3. ENQUADRAMENTO INSTITUCIONAL	7
1.3.1. O MERCADO DA ILUMINAÇÃO DE EMERGÊNCIA	7
1.3.2. A EMPRESA ETAP.SCHRÉDER.....	7
1.3.2. A GAMA LED	10
1.4. ORGANIZAÇÃO DO PROJETO.....	12
2. REVISÃO DE LITERATURA	14
2.1. A IMPORTÂNCIA DA PREVISÃO DE VENDAS.....	14
2.2. MODELOS DE PREVISÃO	16
2.3. PREVISÃO NO MERCADO DA ELETRICIDADE	20
3. METODOLOGIA	24
3.1. PLANO DE TRABALHO.....	24
3.2. MÉTODO DE HOLT-WINTERS.....	26
3.3. MODELO DE REGRESSÃO	27
3.4. MODELOS ARIMA	29
4. ESTUDO EMPÍRICO	33
4.1. CARATERIZAÇÃO DOS DADOS	33
4.2. MÉTODO DE HOLT-WINTERS.....	34
4.3. MODELO DE REGRESSÃO LINEAR MÚLTIPLA	35
4.4. MODELOS ARIMA	37
5. FERRAMENTA DE PREVISÃO	45
6. CONCLUSÕES	48

6.1. CONTRIBUTOS DO PROJETO.....	48
6.2. LIMITAÇÕES.....	49
7. BIBLIOGRAFIA	50
8. ANEXOS	52

ÍNDICE DE ILUSTRAÇÕES

- Ilustração 1 – A fábrica da ETAP em Malle
- Ilustração 2 – O grupo ETAP
- Ilustração 3 – Instalações da ETAP.Schröder em Carnaxide
- Ilustração 4 – Esquema de um LED
- Ilustração 5 – Volume de vendas da iluminação de emergência
- Ilustração 6 – Inquérito feito pelo *The Journal of Business Forecasting*
- Ilustração 7 - Frequência dos documentos sobre LED's brancos
- Ilustração 8 – Metodologia de trabalho
- Ilustração 9 – Diagrama da informação
- Ilustração 10 – Gráfico da amostra
- Ilustração 11 – Explicação da mudança de tempo na amostra
- Ilustração 12 – Cronograma da série cronológica
- Ilustração 13 – Correlograma da série cronológica
- Ilustração 14 - Teste ADF à série cronológica
- Ilustração 15 – Teste KPSS da série cronológica
- Ilustração 16 - Teste ADF da variável corrigida
- Ilustração 17 - Teste KPSS da variável corrigida
- Ilustração 18 – Correlação da variável corrigida
- Ilustração 19 – Resíduos do modelo ARIMA MA (2)
- Ilustração 20 – Método de Holt-Winters sem sazonalidade
- Ilustração 21 – Método de Holt-Winters aditivo
- Ilustração 22 – Método de Holt-Winters multiplicativo
- Ilustração 23 – Método de regressão linear
- Ilustração 24 – Método de regressão quadrática
- Ilustração 25 – Método de regressão linear com *dummies*
- Ilustração 26 – Método de regressão quadrática com *dummies*
- Ilustração 27 – Estimação do modelo ARIMA – MA(1)
- Ilustração 28 – Estimação do modelo ARIMA – MA(2)
- Ilustração 29 – Estimação do modelo ARIMA – AR(1)
- Ilustração 30 – Estimação do modelo ARIMA – AR(2)

ÍNDICE DE TABELAS

Tabela 1 – Principais luminárias de emergência

Tabela 2 – Figurinos teóricos para as ACF e PACF dos modelos ARIMA

Tabela 3 – Resumo dos valores do método de Holt-Winters

Tabela 4 – Resumo dos valores do método de Regressão Linear Múltipla

Tabela 5 – Resumo dos valores do método ARIMA

Tabela 6 – Previsão para o ano de 2012 do método de Holt-Winters multiplicativo

Tabela 7 – Previsão para o ano de 2012 do modelo de regressão quadrática com *dummies*

Tabela 8 – Previsão para o ano de 2012 do modelo ARIMA - MA(2)

Tabela 9 – Comparação da previsão dos modelos

Tabela 10 – Vendas em valor da iluminação de emergência LED

LISTA DE ABREVIATURAS

ADF – Teste Aumentado Dickey-Fuller

AC – *Alternating Current*

ACF – *AutoCorrelation Function*

AIC - *Akaike information criterion*

AR – *Autoregressive*

ARIMA – *Autoregressive Integrated Moving Average*

ARMA – *Autoregressive Moving Average*

B2B – *Business-to-Business*

DC – *Direct Current*

KPSS – Teste de Kwiatkowski-Phillips-Schmidt-Shin

LED – *Light Emitting Diode*

MA – *Moving Average*

PACF – *Partial AutoCorrelation Function*

RLM – Regressão Linear Múltipla

RMSE – *Root Mean Square Error*

SIC - *Schwarz information criterion*

RESUMO

O mercado da iluminação enfrenta atualmente uma profunda alteração motivada pelo desenvolvimento das características dos LEDs. Esta nova fonte de luz traz ao mercado novos progressos, adaptações e desafios.

Todos os *players* presentes no mercado da iluminação estão a renovar o seu portfólio para incluir esta nova fonte de luz. Contudo, enquanto não se dá esta renovação, continua-se a comercializar luminárias de emergência com lâmpadas fluorescentes. Nesta coexistência reside o principal desafio da atualidade em termos de previsão de vendas.

A ETAP, empresa belga de iluminação presente em Portugal desde 1999 com a designação ETAP.Schröder, comercializa entre outros aparelhos de iluminação, luminárias de emergência LED sobre as quais incidirá o presente estudo.

Com o exposto adiante, será possível constatar como a ferramenta da previsão de vendas será um contributo essencial para a gestão comercial face à introdução de uma componente tecnológica num mercado muito competitivo. Assiste-se então a um momento de *phase in - phase out*: com as vendas da gama LED a ganhar mercado perante a gama com lâmpadas fluorescentes, o que torna a previsão de vendas fulcral para o sucesso do negócio.

Através da análise das vendas da gama de emergência LED da ETAP, entre os anos 2008 e 2012, será avaliado qual o melhor método de previsão para essa gama, tendo por base os resultados da estimação no *software EViews*. Com a aplicação do modelo mais adequado, será possível prever a quantidade de stock necessária para satisfazer, em tempo adequado, as encomendas dos clientes da empresa.

Palavras-chave: LED, luminárias de emergência, previsão de vendas, *software EViews*.

ABSTRACT

The lighting market is undergoing a profound change through the development of the LED products. This new light source, the LED, brings a number of new developments, challenges and adjustments.

All players present in the lighting market are renewing their portfolio in order to include this new light source. However, while renovation happens, fluorescent luminaires are still being sold. In this coexistence lies the current main challenge in terms of sales forecast.

The Belgian lighting company ETAP, present in Portugal since 1999 with the name ETAP.Schröder, sells within its wide range of luminaires, LED emergency luminaires which will be the focus of this study.

With all stated bellow, it will be shown how the sales forecast tool is an essential contribution to the commercial management given the introduction of a technological component in a very competitive market. In a moment of phase in - phase out: with LED range sales gaining market when comparing with fluorescent lamps range, sales forecast becomes even more central to business success.

By analyzing ETAP LED emergency range sales between 2008 and 2012, it will be evaluated which sales forecast method is the most appropriate, based on estimation results from EViews Software. Using the most appropriate model it will be possible to forecast the amount of required stock to satisfy, in a timely manner, the company customer's orders.

Keywords: LED, emergency luminaires, sales forecast, EViews software.

SUMÁRIO EXECUTIVO

Nos últimos anos, o mercado da iluminação sofreu, em especial na Europa, uma mudança de paradigma devido à crise económico-financeira: atualmente investe-se menos em novas obras e procura-se melhorar a eficiência energética dos edifícios existentes de modo a reduzir custos operacionais.

O surgir da tecnologia LED, aplicada a cada vez mais soluções de iluminação, veio responder a muitas necessidades do mercado e as vendas deste tipo de soluções têm verificado um aumento significativo nos últimos anos. O segmento de iluminação de emergência é um exemplo especialmente interessante desta evolução.

Ainda assim, apesar das enormes vantagens da tecnologia LED em termos de eficiência, estas são ainda soluções que implicam um investimento mais significativo por parte dos clientes. As soluções com lâmpadas fluorescentes continuam, por isso, a ser uma opção frequente pois permitem cumprir a função com um investimento inicial mais reduzido. Em tempos de crise, ainda que no longo prazo a poupança energética permitida pelas duas soluções dê vantagens à tecnologia LED, se no momento da compra o preço é o fator fundamental de decisão, as soluções com lâmpadas fluorescentes são a opção preferida por clientes com menor poder de compra.

Perante estas condicionantes de mercado, face à introdução de uma nova tecnologia, o desenvolvimento de ferramentas de apoio à gestão comercial na área de previsão de vendas tem vindo a tornar-se fundamental.

Para responder a este propósito, este projeto compreende um estudo empírico capaz de selecionar os modelos de previsão mais ajustados à iluminação de emergência LED, para responder com maior rapidez às encomendas dos clientes, criando o stock necessário para esse efeito.

Para o estudo empírico foram selecionados 3 tipos de luminárias de emergência LED (K7, K8, K9). O histórico de dados que constitui a amostra é composto por quatro anos de vendas líquidas, de periodicidade mensal.

As previsões foram calculadas com base em 3 métodos: de Holt-Winters, de Regressão Linear e modelos ARIMA (Autoregressive Integrated Moving Average).

O modelo ARIMA revelou-se o mais adequado à previsão de vendas da empresa, conseguindo descrever não só o comportamento geral da série cronológica, como também a sazonalidade evidenciada pelos dados.

1. INTRODUÇÃO

A iluminação de emergência está disponível em duas fontes de luz: a lâmpada fluorescente e o LED. A tecnologia das lâmpadas fluorescentes é já muito madura, e o LED tem evoluído bastante a nível tecnológico, sendo hoje a opção mais eficiente. Contudo apresenta ainda um preço mais elevado. Equilibrar o impacto destes dois fatores nas vendas é o objetivo da ETAP.Schröder.

Os fatores determinantes para a realização deste trabalho são o facto de a fonte de luz LED vir a ser impreterivelmente a fonte de luz mais usada no futuro e que a iluminação de emergência na ETAP.Schröder representa 25% da faturação da empresa, quota com tendência a aumentar. Outros aspetos importantes relacionam-se com a necessidade de baixar custos fixos e obter melhores prazos de entrega, o que faz com que a gestão de stock seja crucial para o negócio.

Sendo assim, o objetivo principal deste trabalho é desenvolver um método de previsão de vendas que suporte a gestão de stocks da empresa. Para isso vão ser considerados vários modelos alternativos e, através de critérios de escolha apropriados, pretende-se seleccionar aquele que traduz um menor erro de previsão. Pretende-se dividir a amostra em duas partes: uma para estimação dos parâmetros dos modelos (análise *in-sample*) e outra para a avaliação respetiva (análise *out-of-sample*).

1.1. APRESENTAÇÃO DO PROBLEMA

A iluminação de emergência é habitualmente o grupo de aparelhos cuja instalação entra no plano já muito perto da conclusão da obra, quando a folga em termos de prazos já foi frequentemente esgotada. Assim, desde a decisão de compra até à instalação, decorrem prazos habitualmente reduzidos.

Toda a produção de iluminação de emergência da ETAP.Schröder é feita na fábrica localizada na Bélgica. O tempo de entrega em Portugal, após a encomenda à fábrica, é de cerca de 4 semanas.

A ETAP.Schröder opera no mercado B2B (Business-to-Business), não dispõe de armazém próprio e trabalha com operadores logísticos para transporte e armazenamento de curta duração. Não é por isso comum o armazenamento de elevadas quantidades de existências.

Num mercado tão competitivo como o da iluminação de emergência, o acompanhamento das vendas é tão relevante como a sua projeção para o futuro.

A necessidade de uma maior rapidez na entrega de iluminação de emergência ao cliente desafia a ETAP.Schröder a desenvolver um sistema de previsão de vendas, que lhe permita planear com maior rigor o volume de stock de luminárias LED a ter disponível em Portugal para entrega urgente.

1.2. OBJETIVOS

O principal desafio deste projeto consiste no desenvolvimento de uma ferramenta de previsão de vendas que apoie a área comercial da empresa na gestão de stock de luminárias de emergência LED, a curto, médio e longo prazo.

Pretende-se concluir qual o modelo mais adequado à previsão das vendas mensais de iluminação de emergência LED da ETAP.Schröder.

O estudo pretende ser um contributo importante no processo de decisão relativo ao montante de investimento em stock de luminárias de emergência LED em Portugal. Nesta tomada de decisão, a gestão comercial da ETAP.Schröder poderá assim basear-se num estudo fundamentado na estatística e nos métodos de previsão, ao contrário do que acontece atualmente.

As conclusões deste projeto e os resultados obtidos deverão constituir contributos importantes para operar com sucesso num mercado onde - lado a lado com a necessidade de curtos prazos de entrega - subsiste uma forte dialética entre a eficiência e

o preço dos produtos como fatores de decisão de compra. Com estas condicionantes, o planeamento das encomendas constitui atualmente o maior desafio.

Os vários métodos de previsão de vendas considerados serão estimados a partir do *software Eviews*.

1.3. ENQUADRAMENTO INSTITUCIONAL

1.3.1. O MERCADO DA ILUMINAÇÃO DE EMERGÊNCIA

O mercado da iluminação de emergência insere-se no mercado da iluminação B2B, já que este tipo de iluminação tem fraca expressão de negócio no mercado residencial e na grande distribuição. Ainda que seja difícil apurar o valor exato da iluminação de emergência no mercado, uma vez que as empresas que comercializam estes produtos se dedicam também à venda de iluminação funcional, pode afirmar-se que, no seu todo, o valor estimado do mercado da iluminação interior no B2B é cerca de 100 Milhões Euros.

Este mercado é muito retalhado - nele operam muitos *players*: existem em Portugal mais de 30 empresas neste setor, pelo que a concorrência é fortíssima.

1.3.2. A EMPRESA ETAP.SCHRÉDER

A ETAP.Schröder, teve a sua origem em Janeiro de 1999, como um departamento dedicado à comercialização de aparelhos de iluminação interior, industrial, decorativa e iluminação de emergência, dentro da empresa Schröder Portugal. Fruto da parceria entre a Schröder Portugal e a empresa belga ETAP NV, em 2004 nasce a ETAP.Schröder - como empresa autónoma - em consequência dos bons resultados do departamento criado em 1999.

A ETAP.Schröder está integrada no grupo internacional ETAP Lighting, que desenvolve, produz e comercializa luminárias e sistemas de gestão destinados à iluminação geral e iluminação de segurança.

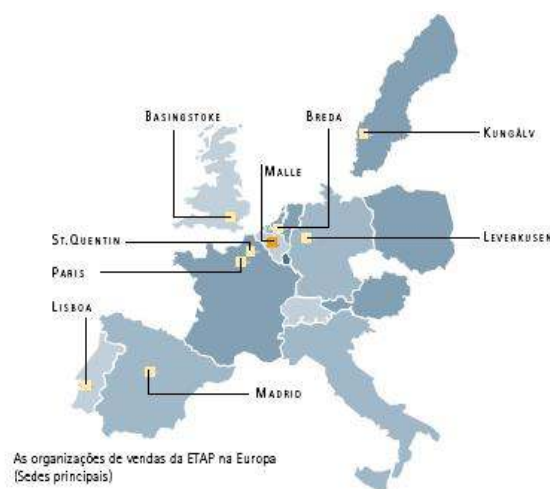


Sede principal, ETAP SA Malle, Bélgica

Ilustração 1 – A fábrica da ETAP em Malle

A ETAP Lighting é uma empresa independente que foi estabelecida em 1949, em Antuérpia. Exerce a sua atividade na área da iluminação profissional de escritórios, fábricas, escolas, hospitais, lojas e hotéis.

Em colaboração estreita com os seus clientes, concebe as melhores soluções de iluminação. Para tal, dispõe de equipas locais de especialistas em iluminação em 11 países. Nesses países, a ETAP emprega cerca de quinhentas pessoas.



As organizações de vendas da ETAP na Europa
(Sedes principais)

Ilustração 2 – O grupo ETAP

Em Portugal, a ETAP.Schröder tem instalações em Carnaxide e no centro de negócios do Freixieiro, no Porto.



Ilustração 3 – Instalações da ETAP.Schröder em Carnaxide

A ETAP desenvolve soluções de iluminação completas: cria conceitos e designs de iluminação, industrializa e produz luminárias, realiza estudos de iluminação, entrega as luminárias e fornece serviços de acompanhamento técnico.

Ao controlar todo o processo, consegue garantir a maior qualidade em todas as fases. Através da inovação contínua, conquistou uma posição de liderança no mercado europeu da iluminação.

Anualmente, a ETAP investe aproximadamente 6 a 7% dos seus lucros em investigação e desenvolvimento de produto. Nos últimos anos a aposta no desenvolvimento de produto com base na tecnologia LED tem sido uma prioridade e toda a gama desenvolvida pela ETAP, independentemente da função, está já disponível na opção LED.

Os principais clientes são instaladores elétricos, armazenistas de material elétrico, donos de obra ou cliente final. Contudo tem como parceiros, todos os intervenientes na prescrição: projetistas de eletricidade e os arquitetos de interiores, a quem oferece as melhores soluções de iluminação.

O volume de vendas da ETAP.Schröder tem vindo a crescer nos últimos anos, muito devido a projetos de grande dimensão como o Parque Escolar em 2010 e a recém-iniciada internacionalização para os mercados de Angola e Moçambique.

A iluminação de emergência representa correntemente cerca de 25% da faturação anual da ETAP.Schröder - incluindo as opções LED e com lâmpadas fluorescentes.

No capítulo 3. serão apresentados 3 modelos de previsão de vendas de possível aplicação à previsão de vendas das luminárias de emergência LED da ETAP.Schröder.

1.3.2. A GAMA LED

LED significa Light Emitting Diode (Díodo Emissor de Luz). Um LED é um semicondutor (díodo) que emite luz ao ser atravessado por corrente elétrica. Os materiais semicondutores utilizados pelos LED convertem a energia elétrica em radiação eletromagnética visível, ou seja, em luz.




Ilustração 4 – Esquema de um LED

Esta tecnologia permite identificar as seguintes vantagens da fonte de luz LED em relação à lâmpada fluorescente:

1. Longa vida útil
2. Elevada eficiência energética
3. Reprodução de cor com elevada qualidade
4. Eficiência da iluminação imediata ao ligar a luz
5. Fácil e vasta amplitude de regulação
6. Ecológicos
7. Ausência de radiação IF ou UV

Apesar da evolução tecnológica, a variada gama de soluções de iluminação de emergência da ETAP inclui ainda modelos com lâmpadas fluorescentes, para além das modernas opções LED.

Representam-se aqui as séries mais relevantes em termos de volume de vendas:







Lâmpadas Fluorescentes			LEDs		
K1	K2	K5	K7	K8	K9
					

Tabela 1 – Principais luminárias de emergência

As soluções de iluminação de emergência com lâmpadas fluorescentes são ainda a opção mais significativa em termos de resultados, se bem que se nota uma evolução decrescente para este tipo de produto. Pelo contrário, a opção LED tem registado uma curva de crescimento de vendas nos últimos anos, como é observável no gráfico seguinte.




Ilustração 5 – Volume de vendas da iluminação de emergência

A evolução positiva das soluções de iluminação de emergência LED identifica estes produtos como inequívocos motores de sucesso comercial no futuro e justifica este estudo dedicado à previsão de vendas deste tipo de produto.

1.4. ORGANIZAÇÃO DO PROJETO

O projeto aqui apresentado está estruturado em seis capítulos: introdução, revisão de literatura, metodologia, estudo empírico, ferramenta de previsão e conclusões.

Na parte introdutória, apresentou-se o problema e os objetivos do projeto, bem como o enquadramento da questão no âmbito do mercado da iluminação de emergência LED, em Portugal.

De seguida, expõe-se o quadro teórico em que o projeto se enquadra através da revisão de literatura, tomando como referência trabalhos semelhantes na área da previsão de vendas.

A metodologia do estudo, apresentada logo após o enquadramento teórico, enuncia os modelos e ferramentas que sustentam a parte prática do estudo: o estudo empírico e as ferramentas de previsão.

O estudo empírico inclui a caracterização dos dados e a estimação de três tipos de modelos diferentes através do software estatístico *EViews* e respetivos comentários.

A parte prática deste estudo termina com a apresentação da ferramenta de previsão selecionada por representar o melhor método, de entre todos os modelos analisados.

Por fim, expõem-se as conclusões e são referidos os principais contributos do estudo, bem como as limitações identificadas.

2. REVISÃO DE LITERATURA

Na escolha do melhor método de previsão, o analista deve ter em consideração os movimentos característicos dos fenômenos em estudo (tendência, sazonalidade, movimentos oscilatórios, existências de observações anômalas e outros movimentos irregulares), o horizonte temporal de previsão (médio, curto ou longo prazo), o número de previsões requeridas e a qualidade das previsões obtidas com os diferentes métodos, para diferentes períodos observados na amostra (análise *out of sample*). O analista pode até encontrar vários métodos ou modelos adequados para descrever o fenômeno em estudo, o que torna difícil a tarefa de escolher o melhor, tal como afirma Caiado (2011).

2.1. A IMPORTÂNCIA DA PREVISÃO DE VENDAS

A aplicabilidade e utilidade da previsão a curto, médio e longo prazo, e o modo como afetam a atividade da empresa, foram alvo de estudo por parte de Jobber e Lancaster (2012).

Segundo estes autores, a capacidade de antecipar o futuro e planejar em conformidade é determinante para o sucesso do trabalho de qualquer diretor comercial. Referem também que é comum constatar que alguns diretores comerciais entendem ainda como mais urgente vender, do que dedicar-se à previsão de vendas. Assim, descuidar esta tarefa resulta frequentemente em decisões tomadas com base em estimativas pouco fundamentadas e sem grande rigor científico. Daqui pode resultar sobreprodução e excesso de stock em relação às vendas reais, ou pelo contrário perda de negócios por falta de produto disponível para entrega.

Jobber e Lancaster (2012) concluem então que a previsão de vendas deve integrar de forma central a missão de qualquer diretor comercial. Só assim será possível definir um plano de negócio com objetivos realistas e planejar com antecedência as melhores estratégias para os alcançar.

A utilidade e aplicabilidade das previsões é diversa consoante se tratem de previsões a curto, médio ou longo prazo, concluíram Jobber e Lancaster (2012):

1. Previsões de curto prazo: aplicam-se geralmente a períodos até três meses e debruçam-se normalmente sobre questões táticas reais, como o planeamento da produção. A tendência real das vendas aqui é menos importante, pois existem apenas flutuações de curto prazo.
2. Previsões a médio prazo: estas têm implicações diretas na direção comercial. São as previsões mais importantes na área do orçamento comercial, o ponto de partida para a previsão de vendas. Assim, se a previsão de vendas é incorreta, todo o orçamento está incorreto. Se a previsão é mais otimista, a empresa terá demasiado stock que poderá não conseguir vender. Se a previsão é pessimista, a empresa pode perder oportunidades de marketing, por não estar habilitada a acompanhar o que o mercado pretende. O exposto permite reenfatizar o ponto de que a previsão de vendas é da responsabilidade do diretor comercial. Tais previsões a médio prazo têm normalmente um ano de antecedência.
3. Previsões a longo prazo: fazem-se geralmente por períodos de três anos, ou mais, dependendo do tipo de mercado a considerar. Em setores como o dos computadores, três anos é considerado longo prazo; enquanto para o fabrico de aço, 10 anos é um horizonte de longo prazo típico. Estas previsões são obtidas a partir de fatores macro-ambientais tais como políticas governamentais, tendências económicas, etc. Tais previsões são necessárias principalmente para os gestores financeiros, para as implicações a longo prazo de recursos, e são geralmente a preocupação dos conselhos de administração.

Segundo Justino (2007), a previsão das vendas é a peça mais importante na gestão e planeamento da atividade comercial.

Reforça ainda que os gestores usam a previsão de vendas para imputar os recursos existentes às diferentes áreas funcionais da empresa.

Justino (2007) completa com os seguintes exemplos:

- A área financeira usa as previsões para estimar os *cash-flows*, tomar decisões acerca de investimentos e para elaborar orçamentos;
- A área da produção utiliza-as para estimar as quantidades a produzir, o programa de produção e controlar as existências;
- Os recursos humanos usam-nas para planejar os recrutamentos, os despedimentos e as reconversões;
- O departamento de marketing usa as previsões para antecipar vendas e canalizar os recursos para as diferentes atividades do marketing, etc;

Assim, facilmente se percebe que as previsões devem ter em conta a área da empresa a que se destinam e até mesmo as finalidades com que são efetuadas.

2.2. MODELOS DE PREVISÃO

De acordo com Fliedner (2001), a aplicabilidade de um modelo de previsão depende apenas de três condições:

1. Disponibilidade de informações históricas
2. Possibilidade da transformação das informações históricas em dados numéricos
3. Suposição da repetição de padrões observados em dados passados no tempo futuro

Para este autor, esta última consideração é conhecida como a suposição da continuidade. Tal condição é uma premissa básica para a utilização dos modelos de previsão.

Para Jain (2007) a seleção do modelo a usar é a parte mais importante da previsão. Para obter os melhores resultados é necessário usar o modelo mais indicado na amostra em causa.

Segundo Jain (2007), existem três tipos de métodos de previsão:

1. Modelos de séries cronológicas
2. Modelos causais
3. Métodos qualitativos

Os modelos de séries cronológicas envolvem a extrapolação de dados históricos por métodos estatísticos que representem uma melhor adequação a esses dados. O autor refere que esses modelos estatísticos incluem: médias simples e móveis, tendências simples, métodos de alisamento e de decomposição e modelos ARIMA.

Relativamente aos modelos causais, existe uma ou mais causas (variáveis independentes) e o efeito (variável dependente). Estes modelos de causa-efeito projetam relações futuras, quando as variáveis demonstram uma relação estatisticamente significativa no passado.

Por fim, relativamente aos métodos qualitativos, Jain (2007) refere que estes são usados frequentemente quando não existem dados históricos, como no caso de novos produtos; existindo dados históricos de produtos semelhantes ou noutros mercados, estes modelos não são apesar de tudo aplicáveis, como acontece na indústria da moda.

Jain (2007), refere ainda que antes de selecionar e usar um modelo, é importante ter em conta princípios e conceitos elementares relativos aos modelos e a respetiva modelação.

Listam-se de seguida os princípios essenciais, segundo este autor:

1. Dado atual = estimação + erro
2. Não é necessário 100% de precisão
3. Mais dados não significa necessariamente melhor modelo
4. Modelos sofisticados não são necessariamente melhores
5. Não há nenhum modelo mágico
6. Modelos mudam com o tempo
7. Cada modelo tem o seu próprio requisito

8. Previsões estatísticas não são mais do que previsões de base
9. As previsões não devem ser preparadas isoladamente

Na verdade, indica o mesmo autor, o mais importante é aprofundar o conhecimento acerca de cada um dos modelos, nunca perder de vista os princípios acima citados e praticar a sua aplicação. Deste modo, a seleção e a utilização dos modelos traduzir-se-á num trabalho de rigor cada vez mais apurado.

Ainda assim, apesar da diversidade de modelos disponíveis para aplicação nas mais diversas áreas, constata-se uma parca dispersão na utilização dos mesmos.

Tendo em conta os gráficos abaixo apresentados, verifica-se que os modelos de séries cronológicas (72%) são os mais usados pelas empresas e que apenas 11% dessas empresas recorre a métodos qualitativos. Para os modelos causais a percentagem é de 17%.

Os resultados da ilustração seguinte foram registados num inquérito sobre os modelos de previsão mais utilizados, realizado a várias empresas em 2006, pelo *The Journal of Bussiness Forecasting*.

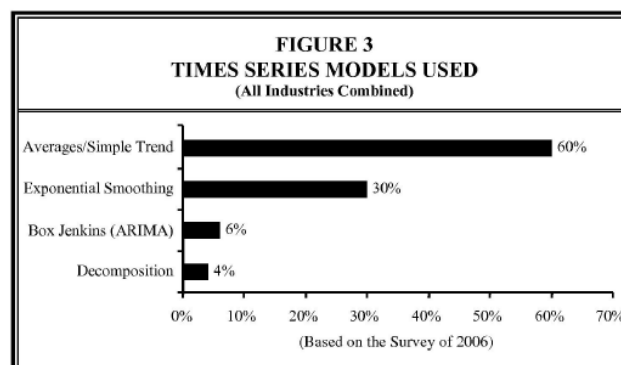
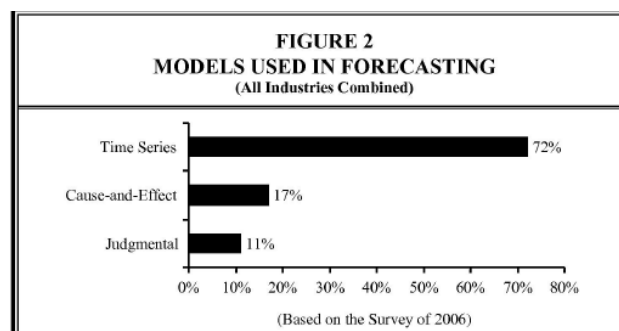


Ilustração 6 – Inquérito feito pelo *The Journal of Business Forecasting*

Jain (2007) atribui a preferência dada aos modelos de séries cronológicas à facilidade de modelação e interpretação que apresentam, bem como pelo seu bom desempenho nas previsões a curto prazo. A ilustração anterior reflete ainda, no segundo gráfico, a percentagem de uso dos vários modelos de séries cronológicas nas empresas.

Segundo Jain (2007), os modelos de séries cronológicas são usados em grande parte da indústria - principalmente na indústria química - no retalho e nas telecomunicações. Os modelos causais são usados principalmente nas indústrias automóvel e alimentar. Os métodos qualitativos são muito populares na indústria farmacêutica.

Também Gilliland e Leonard (2006) referem que através das ferramentas de previsão é possível extrair dos dados passados disponíveis informações que permitem a modelagem matemática do seu comportamento. A suposição de uma continuidade nesse comportamento permite a realização de previsões, cuja qualidade e precisão são muito superiores as previsões feitas intuitivamente, baseadas unicamente na experiência dos decisores.

Para além do exposto, Radovilsky e Eyeck (2000) demonstram que o Excel constitui uma boa alternativa aos principais programas estatísticos de previsão, por vários motivos: primeiro, por ser uma ferramenta bastante popular no mundo dos negócios. Segundo porque os dados das vendas estão organizados em folhas de cálculo de Excel. Por fim, o programa dispõe de ferramentas próprias de previsão. Contudo, os autores referem também que o Excel não é um software especializado em previsões o que faz com que em negócios com um número alargado de produtos e serviços este software não seja o mais indicado.

Acerca do uso de software especializado na previsão de vendas, Jobber e Lancaster (2012) mencionam a facilidade com que novas ferramentas surgem, tornando as existentes ultrapassadas. Ainda assim, destacam alguns dos softwares que melhor têm acompanhado a evolução dos tempos:

SPSS - software de análise estatística muito utilizado devido à facilidade com que disponibiliza múltiplas técnicas e métodos estatísticos para aceder aos dados

introduzidos, transformá-los de acordo com os pressupostos analíticos, e selecionar e aplicar procedimentos estatísticos.

MINITAB - permite obter estatísticas descritivas, simulações e distribuições, inferência estatística elementar, análise da variância, regressão, análise de dados categóricos, métodos não paramétricos e análise de séries temporais, entre outros.

EViews - poderosa ferramenta de estatística, previsão e modelagem através de um interface fácil de usar, o que faz do EViews uma ferramenta ideal para trabalhar com séries temporais, secção transversal ou dados longitudinais.

Ainda acerca das ferramentas utilizadas nas previsões de vendas, Cuddington (2011) salienta a potencialidade do software EViews na integração de séries financeiras neste tipo de previsões. Destaca este autor que esta possibilidade de integração permite uma previsão mais fácil e transparente, quando comparada com a utilização de outros *softwares*.

Por fim, Curto (2009) refere que os valores que resultam da previsão não condicional podem ser comparados com os valores realmente observados pela variável dependente. Neste caso é possível avaliar o modelo *in-sample* com base nos erros de ajustamento. Se algumas das observações amostrais não forem incluídas na estimação dos parâmetros, os valores que resultam da previsão *ex-post* também podem ser comparados com os valores realmente observados pela variável dependente. Em ambos os casos é possível calcular os erros de ajustamento e de previsão, pois estão disponíveis os valores exatos quer para a variável dependente, quer para as variáveis explicativas, isto no caso dos modelos causais.

2.3. PREVISÃO NO MERCADO DA ELETRICIDADE

No mercado da iluminação, a que este estudo diz respeito, é insipiente a referência à previsão de vendas ou fabrico de luminárias, em artigos científicos, livros ou outras fontes.

Cumpramos então estender a nossa análise ao mercado elétrico, onde podemos encontrar casos mais atuais de utilização de previsões. São exemplo disso a previsão de carga na rede elétrica e a previsão de tendência em tecnologia, neste caso específico nos LED brancos.

Hong (2010) utilizou três métodos para fazer previsão de carga na rede elétrica: lógica de instinto, redes neurais e modelos sazonais. Para os modelos sazonais, foram tidos em conta cinco métodos: ARIMA, AR periódico, Holt-Winters, uma formulação baseada no alisamento exponencial e um outro baseado no método qualitativo. O caso de estudo envolve dez séries de 10 países europeus, por um período de 30 semanas.

Como resultado, Hong (2010) verificou que o melhor método para o caso estudado era o de Holt-Winters. O autor acrescentou ainda que esta avaliação cobriu uma quantidade razoável de representativos métodos de previsão, que mostraram precisão satisfatória para execução a curto prazo (quatro a seis horas a diante). Para conseguir previsões mais prolongadas no tempo, mostrou-se necessário incluir no modelo a previsão das condições climáticas.

Relativamente ao tema da previsão da tendência em tecnologia, Suominen e Seppänen (2011) referem que a previsão tecnológica tem por objetivo fornecer informação atempada sobre as perspectivas de uma nova tecnologia. O processo de previsão, como tal, pode ser feito com vários métodos diferentes, alguns dos quais são métodos qualitativos e outros que dependem da quantificação de séries cronológicas.

Estes autores afirmam que as previsões - ou extrapolações de tendências, tal como as previsões neste contexto são muitas vezes referidas - são frequentemente feitas tendo por base um modelo em forma de S, que se designa por curva de crescimento. Curvas de crescimento em forma de S constituem segundo os autores a melhor representação dos processos de crescimento tecnológico, embora outros métodos de previsão - tal como ARIMA - também tenham sido utilizados. As circunstâncias que podem influenciar a escolha de um ou outro modelo relacionam-se com a disponibilidade de dados: com poucos dados históricos deverá prevalecer a escolha do modelo da curva em

forma de S; pelo contrário, a existência de dados históricos potencia a qualidade das previsões utilizando o modelo ARIMA.

No seu estudo, Suominen e Seppänen (2011) identificaram a existência de LEDs brancos desde o início dos anos 60, segundo a série de dados selecionada no *US Patent and Trademark Office*. Após a análise desta base de dados, listaram o resumo apresentado na ilustração seguinte, sobre a frequência dos documentos que continham informação sobre LEDs brancos.

Table 3: Cumulative document frequency on white LEDs.

Year	SCI	Compendex	Patents	News
1991		1		
1992		1		
1993		1		
1994		2		
1995		2		
1996	1	3		
1997	7	6	2	5
1998	9	7	5	6
1999	17	10	15	15
2000	27	18	25	22
2001	39	38	37	41
2002	60	60	44	86
2003	87	92	67	144
2004	139	149	85	208
2005	205	229	108	285
2006	293	316	121	341
2007	414	417	128	410
2008	587	570	130	473
2009	823	764	130	565

Ilustração 7 - Frequência dos documentos sobre LED's brancos

A utilização de um algoritmo de busca utilizando as palavras "LED branco", "LEDs brancos", "díodo emissor de luz branca" e "diodos emissores de luz branca", através de um processo de tentativa e erro, foi a única forma de encontrar as entradas de dados relevantes. Os primeiros *outputs* encontrados em cada umas das bases de dados tiveram de ser validados pela opinião de um *expert* para certificar de que o ponto de partida de cada conjunto de dados tinha sido definido corretamente.

Estes autores concluíram que os modelos mais utilizados nas curvas em forma de S são as de Fisher-Pry e de Gompertz. Sendo que o modelo de Fisher-Pry é mais utilizado para prever a taxa de substituição de uma tecnologia por outra. Já o modelo de Gompertz é mais apropriado em casos nos quais a substituição tecnológica se dá mais pela deterioração do equipamento antigo do que pela novidade tecnológica em si mesma.

Os estudos aqui apresentados permitem consolidar o enquadramento teórico do presente projeto e situar este trabalho dentro da área de pesquisa relativa aos métodos e modelos de previsão.

Feita que está a contextualização, segue-se a apresentação do plano metodológico.

3. METODOLOGIA

Neste capítulo apresentar-se-á a explicação detalhada de todas as ações desenvolvidas neste estudo. Inclui a caracterização dos métodos de Holt-Winters, modelo de regressão e modelo ARIMA, bem como das amostras e procedimentos usados para obter as conclusões apresentadas neste estudo.

3.1. PLANO DE TRABALHO

A estimação dos parâmetros dos modelos e a previsão das vendas serão feitas a partir do *software EViews*, com as seguintes etapas metodológicas:

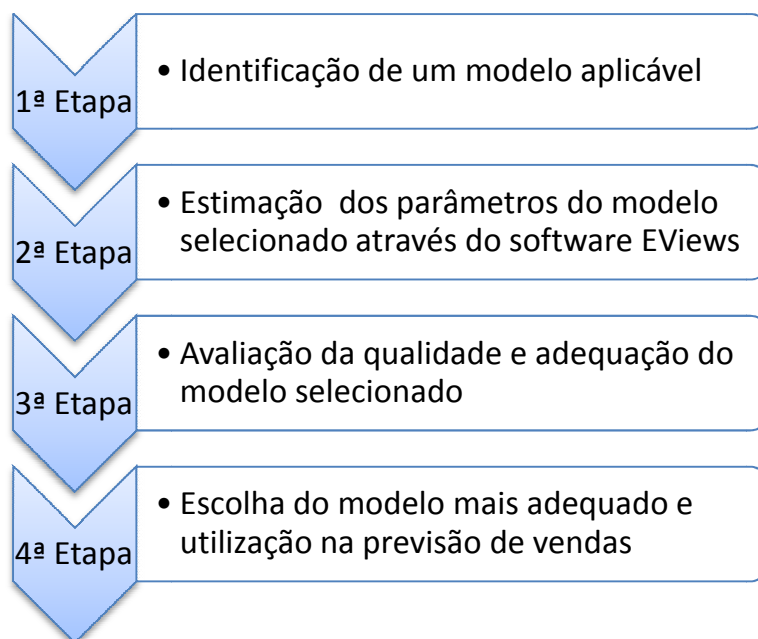


Ilustração 8 – Metodologia de trabalho

Na primeira etapa, identificam-se os métodos e os respetivos parâmetros. Na segunda etapa, constrói-se para cada modelo, uma tabela resumo que inclui os dados estimados através do software *EViews*. Nesta fase reduz-se a amostra total de 60 observações, para apenas 48 observações (análise *in-sample*), de modo a utilizar as restantes 12 observações (análise *out-of-sample*) para avaliação do modelo.

Nesta fase de avaliação - terceira etapa - procura-se identificar o modelo que melhor descreve os dados da amostra. Por fim, uma vez identificado e estimado o modelo, procede-se à previsão do ano de 2012.

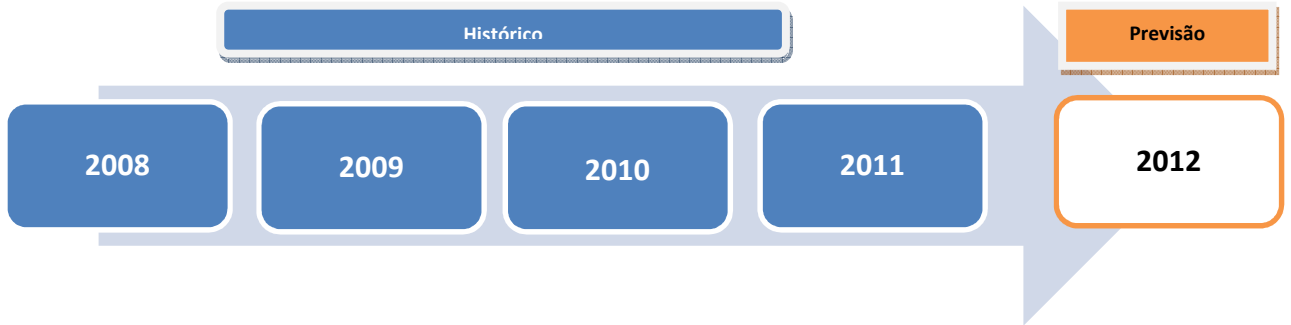


Ilustração 9 – Diagrama da informação

Neste trabalho de escolha do modelo mais adequado, considerar-se-á como critério de escolha o RMSE (*Root Mean Square Error*) e o melhor modelo será o que apresentar o valor mais reduzido. Contudo o modelo com mais baixo RMSE não garantirá um menor erro futuro, apenas apresentará uma menor probabilidade de tal acontecer com base no histórico.

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{t=1}^n (Y_t - \hat{Y}_t)^2} \quad (1)$$

Y_t – Valor observado da variável dependente

\hat{Y}_t - Valor previsto pelo modelo

n – Número de períodos

O objetivo central da utilização dos métodos de previsão é prever os acontecimentos futuros, tendo como propósito a redução do risco na tomada de decisão. Normalmente, as previsões estão sempre erradas, mas a magnitude dos seus erros depende muito do modelo de previsão utilizado. Uma maior disponibilização de recursos no método de previsão implementado permite melhorar a precisão da previsão e, assim, eliminar alguns dos problemas resultantes da incerteza existente no processo de tomada de decisão.

Neste estudo consideram-se e aplicam-se três tipos de métodos de previsão:

- Método de Holt – Winters
- Modelo de Regressão Linear
- Modelo ARIMA

3.2. MÉTODO DE HOLT-WINTERS

Os métodos de alisamento exponencial são métodos de previsão que atribuem pesos exponencialmente decrescentes com a antiguidade das observações. Em geral, estes métodos são úteis para a previsão de séries com tendência (linear ou amortecida) e séries com sazonalidade (de efeitos aditivos ou multiplicativos). As vantagens dos métodos de alisamento em relação a outros métodos de previsão são a simplicidade de utilização e o baixo custo de computação.

Dos vários métodos de alisamento que existem, destaca-se o método de Holt-Winters por poder lidar ao mesmo tempo com uma tendência linear e com a sazonalidade. O método baseia-se em três equações de alisamento: uma para o nível da tendência, uma para o declive da tendência e outra para a sazonalidade. De forma reduzida, as equações de alisamento a usar são as seguintes:

$$S_t = \alpha \frac{Y_t}{I_{t-1}} + (1 - \alpha)(S_{t-1} + b_{t-1}) \quad (2)$$

$$b_t = \beta(S_t - S_{t-1}) + (1 - \beta)b_{t-1} \quad (3)$$

$$I_t = \gamma \frac{Y_t}{S_t} + (1 - \gamma)I_{t-1} \quad (4)$$

Em que $0 < \alpha < 1$, $0 < \beta < 1$ e $0 < \gamma < 1$.

A primeira equação define o estimador para o nível de tendência no respectivo momento t. A segunda equação faz a estimação do declive da tendência. A última equação estima a componente sazonal no período t.

A equação de previsão fica assim definida:

$$\hat{y}_{t+h} = (S_t + b_t h) I_{t+h-kl} \quad (5)$$

Com $h = 1, 2, \dots$ e $k = 1$ se $0 < h \leq l$, $k = 2$ se $l < h \leq 2l$, sendo que l é a duração de um ciclo sazonal.

O método permite duas abordagens diferentes para a sazonalidade: modelos aditivos e multiplicativos. Nos modelos aditivos, o padrão sazonal não se altera à medida que o nível da série cresce ou decresce. Ao contrário, nos modelos multiplicativos, a sazonalidade da série é afetada pelo nível da mesma.

3.3. MODELO DE REGRESSÃO

O modelo de regressão estabelece a relação funcional entre uma variável dependente (ou explicada) e uma ou mais variáveis independentes (ou explicativas). A previsão da variável dependente é obtida em função dos valores conhecidos das variáveis independentes que podem influenciar o seu comportamento no futuro.

O modelo de regressão linear simples é uma das formas mais básicas de observar uma relação entre duas variáveis e é apresentado desta forma:

$$Y_t = \beta_1 + \beta_2 X_{2t} + \varepsilon_t \quad (6)$$

Sendo que:

- Y – variável dependente
- X_2 – variável independente
- t – observação no tempo dos dados da amostra
- β_1 e β_2 – coeficientes de regressão (β_1 é a ordenada na origem e β_2 o declive da reta)
- ε_t – variável aleatória designada erro (parte aleatória do modelo)

Neste caso, e por estar em causa a forma mais simples de regressão, aproxima-se a função da amostra a uma reta (função de primeiro grau), ainda que possa fazer-se a aproximação da amostra a outra função, como a função quadrática (segundo grau), a função logarítmica e a função exponencial, entre outras. O que mudaria na última função descrita seria a componente determinística ($\beta_1 + \beta_2 X_{2t}$) pois caracteriza matematicamente a função a representar. A variável aleatória (termo de erro) estará sempre presente para representar outros fatores que podem influenciar o comportamento da variável dependente.

O objetivo deste método é minimizar a soma dos quadrados dos resíduos:

$$\sum_{t=1}^n (Y_t - \hat{Y}_t)^2 \quad (7)$$

Sendo Y_t o valor observado e \hat{Y}_t o valor estimado a partir dos dados da amostra.

Como já foi referido, alguns modelos determinísticos de avaliação da tendência são não lineares. Os mais comuns são os de tendência exponencial, geométrica e logarítmica. Estes modelos podem ser facilmente estimados pelo método dos mínimos quadrados, mediante prévias transformações adequadas, como por exemplo a transformação logarítmica, que permite transformar modelos explicativos em aditivos e linearizar as funções exponenciais e geométricas.

Por outro lado, o modelo de regressão linear múltipla descreve a relação entre duas ou mais variáveis independentes a uma única variável dependente ou explicativa através da forma funcional:

$$Y_t = \beta_1 + \beta_2 X_{2t} + \beta_3 X_{3t} + \dots + \beta_k X_{kt} + \varepsilon_t \quad (8)$$

Sendo que:

- Y – variável dependente ou explicativa
- X_2, X_3, \dots, X_k – (k-1) variáveis independentes
- t – observação no tempo dos dados da amostra

- $\beta_1, \beta_2, \dots, \beta_k$ – coeficientes de regressão
- ε_t – variável aleatória designada erro (parte aleatória do modelo)

Este modelo pode ser apresentado na seguinte forma compacta, na sua forma matricial:

$$\mathbf{Y} = \mathbf{X}\boldsymbol{\beta} + \boldsymbol{\varepsilon} \quad (9)$$

Onde \mathbf{Y} é o vetor coluna ($n \times 1$) das observações da variável dependente ou explicativa; \mathbf{X} é a matriz ($n \times K$) das observações das $k-1$ variáveis independentes; $\boldsymbol{\beta}$ é o vetor coluna ($k \times 1$) dos parâmetros ou coeficientes de regressão; $\boldsymbol{\varepsilon}$ é o vetor coluna ($n \times 1$) dos erros aleatórios.

Para modelar a sazonalidade devem criar-se variáveis independentes tipo *dummies* ou binárias. Estas variáveis têm valor 1 sempre que ocorrem períodos de forte sazonalidade não captada pelos modelos e valor 0 nos restantes casos.

3.4. MODELOS ARIMA

São modelos mais sofisticados do que os anteriores, e baseiam-se nas correlações entre as observações em diversos instantes. Os modelos ARIMA costumam apresentar melhores resultados que os métodos de alisamento ou de regressão desde que a série cronológica seja relativamente longa e “bem comportada”. Se a série é muito irregular, os resultados são - geralmente - inferiores aos obtidos pelos modelos anteriores.

As duas componentes dos modelos ARIMA (p,d,q) são as seguintes: AR (Autoregressiva) e MA (Médias Móveis). Sendo que o significado de p é a ordem do processo autoregressivo, d é o nível de diferenciação e q é a ordem do processo de médias móveis. Numa série estacionária $d=0$, pelo que se apresenta num modelo ARMA (p,q).

Os modelos ARIMA são aplicados em séries cronológicas estacionárias, ou seja, séries onde a tendência deve ser neutra e com a variância estabilizada ao longo da amostra.

Normalmente a maioria das séries não são estacionárias, necessitando de ser transformadas até conseguir a sua estacionarização.

Formalmente, a estacionaridade de uma série cronológica Y_t implica média e variância constantes, e covariância independente do tempo t . Na prática, a estacionaridade de uma série temporal observa-se quando os dados não apresentam tendência crescente ou decrescente, nem apresentam movimentos periódicos. Para além disso flutuam em torno de um nível constante, independente do tempo, e a variância das flutuações não se altera ao longo do tempo.

As três transformações mais habituais para tornar uma série cronológica estacionária são as seguintes:

1. A de Box-Cox que permite estabilizar a variância,

$$Y_t^{(\lambda)} = \begin{cases} \frac{Y_t^\lambda - 1}{\lambda} & \text{se } \lambda \neq 0 \\ \ln Y_t & \text{se } \lambda = 0 \end{cases} \quad (10)$$

2. A definida pelo operador “diferenciação simples” para neutralizar a tendência,

$$\nabla Y_t = Y_t - Y_{t-1} \quad (11)$$

3. A definida pelo operador “diferenciação sazonal” para eliminar movimentos estritamente periódicos,

$$\nabla_s Y_t = Y_t - Y_{t-s} \quad (12)$$

Considerando uma série temporal, $\{\varepsilon_t\}$, de variáveis aleatórias não correlacionadas de valor médio nulo e desvio padrão σ_ε (ruído branco); um modelo misto ARMA (p,q) é definido pela equação:

$$Y_t - \phi_1 Y_{t-1} - \dots - \phi_p Y_{t-p} = \varepsilon_t - \theta_1 \varepsilon_{t-1} - \dots - \theta_q \varepsilon_{t-q} \quad (13)$$

Utilizando um operador de desfasamento, L ($LY_t=Y_{t-1}$),

$$\phi_p(L)X_t = \theta(L)\varepsilon_t \quad (14)$$

O modelo ARMA (p,q) sem o termo constante, para uma variável estacionária Y_t é usualmente definido por:

$$\phi(L) Y_t = \theta(L) u_t \quad (15)$$

Admite-se que neste modelo os parâmetros ϕ_i ($i=1,\dots,p$) e θ_i ($i=1,\dots,q$) são tais que as raízes dos polinómios $\phi(L)$ e $\theta(L)$ são estritamente em módulo superior à unidade.

Se $p=0$ o modelo diz-se de médias móveis de ordem q, MA (q), e se $q=0$ diz-se autoregressivo de ordem p, AR(p).

Pode assim, considerar-se três classes de modelos lineares finitos, sendo cada uma delas bem caracterizada em termos das funções de autocorrelação (ACF) e autocorrelação parcial (PACF). Abaixo apresentam-se as características esperadas destas duas funções para os três modelos lineares considerados.

	AR (p)	MA (q)	ARMA (p,q)
ACF	Decaimento exponencial ou sinusoidal amortecido para zero	Queda brusca para zero a partir de lag q+1	Decaimento exponencial ou sinusoidal para zero
PACF	Queda brusca para zero a partir de lag p+1	Decaimento exponencial ou sinusoidal para zero	Decaimento exponencial ou sinusoidal para zero

Tabela 2 – Figurinos teóricos para as ACF e PACF dos modelos ARIMA

Na etapa de identificação das ACF e PACF, são estimadas as funções a partir da informação fornecida pelos valores observados da série cronológica, devendo - em seguida - ser comparadas com os figurinos teóricos destas funções para cada um dos modelos acima referidos.

A apresentação dos modelos acima descritos encerra os capítulos teóricos deste estudo, passando-se de seguida aos capítulos de teor prático, onde se procederá à estimação e previsão dos modelos de previsão.

4. ESTUDO EMPÍRICO

O estudo empírico aqui apresentado, tem por base uma amostra retirada do sistema de faturação da empresa ETAP.Schröder que será utilizada para prever as vendas da gama de emergência LED da ETAP. Para fazer a previsão dessas vendas vão ser considerados os seguintes modelos de previsão: método de Holt-Winters, modelo de regressão linear e modelos ARIMA. A estimação destes modelos será feita através do *software EViews*.

O objetivo central da utilização dos métodos de previsão é antever os acontecimentos futuros, tendo como propósito a redução do risco na tomada de decisão. Normalmente, as previsões tem por inerência erros, mas a magnitude desses erros depende muito do método de previsão utilizado. Uma maior disponibilização de recursos no método de previsão implementado permite-nos melhorar a precisão da nossa previsão e, assim, reduzir a incerteza no processo de tomada de decisão.

4.1. CARACTERIZAÇÃO DOS DADOS

Os dados analisados correspondem ao valor de faturação da empresa ETAP.Schröder relativa à gama de iluminação de emergência LED da ETAP. Os valores são mensais e correspondem aos anos de 2008 a 2012. Por questões de confidencialidade, foi feita uma correção proporcional dos valores apresentados na amostra, alvo do presente estudo, pelo que os valores diferem da realidade.

A representação gráfica dos dados é a primeira etapa na análise de séries cronológicas.




Ilustração 10 – Gráfico da amostra

Em geral consideram-se quatro componentes numa série cronológica, designadas por componentes tendência, sazonal, cíclica e irregular. Pelo cronograma acima constata-se uma tendência crescente nas vendas de luminárias de emergência LED. Podem também observar-se variações sazonais na amostra.

No sentido de avaliar a capacidade preditiva dos diversos métodos de previsão, a amostra foi dividida em duas partes: as primeiras 48 observações (análise *in-sample*) são utilizadas para estimar os parâmetros dos modelos e as restantes 12 (análise *out-of-sample*) servem para avaliar e comparar a capacidade preditiva dos modelos concorrentes.




Ilustração 11 – Explicação da mudança de tempo na amostra

Para tal seleciona-se o modelo que melhor resultado obtiver neste capítulo, assumindo-se sempre como “melhor” modelo aquele que minimizar o RMSE:

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (Y_t - \hat{Y}_t)^2}$$

Sendo n=12, para o presente caso.

4.2. MÉTODO DE HOLT-WINTERS

Tendo em conta a evolução tendencialmente crescente das vendas e as variações sazonais observadas, o método de alisamento de Holt-Winters foi utilizado com tendência linear, sem e com sazonalidade (aditivo e multiplicativo). Os resultados obtidos são apresentados na tabela seguinte:

Métodos	Holt - Winters sem sazonalidade	Holt - Winters aditivo	Holt - Winter multiplicativo
Nível da tendência	15.844,87	14.695,89	14.695,89
Declive da tendência	404,42	198,49	198,49
Jan		-7.600,98	0,08
Fev		-6.611,97	0,23
Mar		-685,47	0,99
Abr		-4.321,47	0,48
Mai		-4.644,96	0,49
Jun		-1.843,46	0,81
Jul		18.458,04	2,99
Ago		-8.677,95	0,10
Set		-6.813,94	0,34
Out		-2.887,44	0,79
Nov		851,56	1,20
Dez		24.778,07	3,49
RMSE	11.576,63	4.830,79	3.426,38

Tabela 3 – Resumo dos valores do método de Holt-Winters

Comparando os resultados dos vários erros quadráticos médios (RMSE), observa-se que o método de Holt-Winters que melhor se ajusta à amostra é o multiplicativo, por apresentar o menor valor para o RMSE. Assim, a ter que escolher o melhor método para efetuar a previsão dentro deste modelo, escolher-se-ia o método de alisamento multiplicativo.

4.3. MODELO DE REGRESSÃO LINEAR MÚLTIPLA

Na aplicação do modelo de regressão linear múltipla, considera-se três formas funcionais:

1. Modelo com tendência linear
2. Modelo com tendência quadrática
3. Modelo com tendência e sazonalidade, introduzindo variáveis *dummies* para os meses considerados

Para modelar a sazonalidade da série cronológica será necessário criar 11 variáveis *dummy* para representar a sazonalidade de cada mês (*jan, fev, mar, abr, mai, jun, jul, ago, set, out, nov*). O número de *dummies* é sempre igual ao período da sazonalidade menos 1, neste caso $12-1=11$, para evitar problemas de colinearidade perfeita entre as variáveis explicativas.

Os resultados obtidos da aplicação do modelo de regressão linear múltipla estão resumidos na tabela seguinte:

Métodos		Tendência Linear	Tendência Quadrática	Tendência Linear + Sazonalidade	Tendência Quadrática + Sazonalidade
C	coef.	2.627,88	5.855,96	29.651,04	32.453,47
	P value	0,43	0,26	0,00	0,00
T	coef.	273,05	-114,31	184,54	-167,55
	P value	0,02	0,81	0,00	0,47
T ²	coef.		7,90		7,18
	P value		0,41		0,12
Jan	coef.			-32.532,47	-32.532,47
	P value			0,00	0,00
Fev	coef.			-31.529,51	-31.457,60
	P value			0,00	0,00
Mar	coef.			-25.589,06	-25.459,72
	P value			0,00	0,00
Abr	coef.			-29.211,11	-29.038,65
	P value			0,00	0,00
Mai	coef.			-29.520,66	-29.319,46
	P value			0,00	0,00
Jun	coef.			-26.705,21	-26.489,64
	P value			0,00	0,00
Jul	coef.			-6.389,75	-6.174,18
	P value			0,11	0,12
Ago	coef.			-33.511,81	-33.310,61
	P value			0,00	0,00
Set	coef.			-31.633,85	-31.461,40
	P value			0,00	0,00
Out	coef.			-27.693,40	-27.564,06
	P value			0,00	0,00
Nov	coef.			-23.940,45	-23.868,59
	P value			0,00	0,00
F-test		5,29	2,96	14,82	14,42
Significância F		0,02	0,06	0,00	0,00
R ² Ajustado		0,08	0,07	0,77	0,78
RMSE		11.391,03	11.431,42	5.590,89	5.480,91

Tabela 4 – Resumo dos valores do método de Regressão Linear Múltipla

Do ponto de vista da qualidade estatística, pode-se dizer que as variáveis são estatisticamente relevantes para explicar o valor das vendas da gama de emergência LED, porquanto os valores de prova (P-value) associados aos respectivos parâmetros são claramente inferiores a 0,05 (considerando um nível de significância de 5%).

Tendo em conta o valor mais reduzido do RMSE, o modelo a seleccionar deve ser o modelo de tendência quadrática com *dummies*. Assim sendo, é este o modelo mais adequado à previsão, de entre os métodos relativos ao modelo de regressão linear apresentados.

4.4. MODELOS ARIMA

Neste ponto, apresenta-se sumariamente a metodologia de modelação ARIMA de séries temporais, que consiste nas etapas de representação, verificação, avaliação do diagnóstico e selecção de modelos. Se o modelo seleccionado for adequado, pode passar-se a uma outra etapa, que diz respeito à previsão.

Na análise de uma série cronológica os passos a considerar são os seguintes:

1. Representar a série cronológica graficamente (cronograma)
2. Verificar a estacionariedade da série cronológica através dos testes ADF e KPSS
3. Proceder à diferenciação da série, se esta não é estacionária
4. Avaliação de um modelo e a sua construção

No primeiro passo apresenta-se a cronograma da série cronológica:

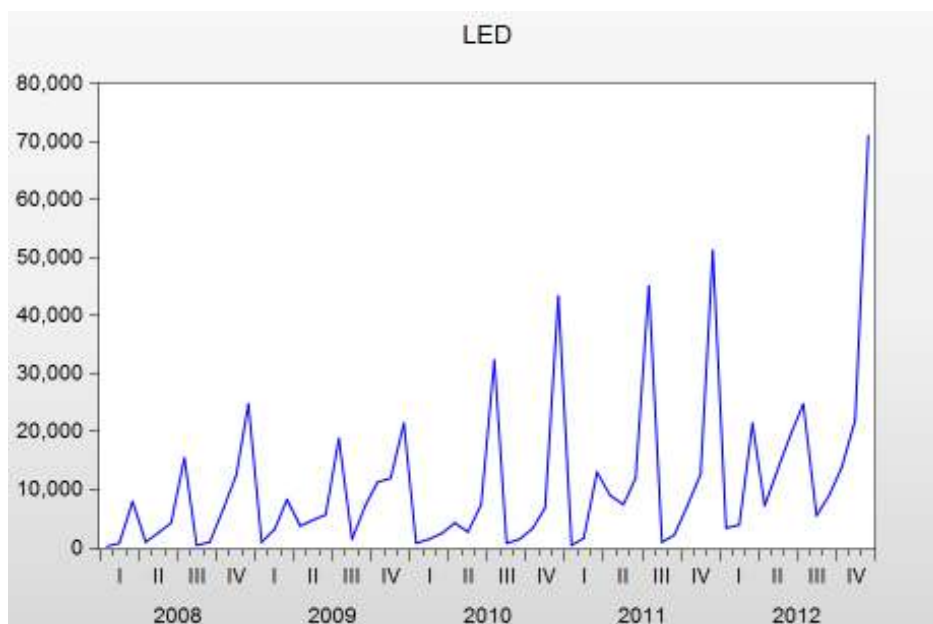


Ilustração 12 - Cronograma da série cronológica

Através do cronograma, pode verificar-se a existência da tendência, variância não constante e efeito de sazonalidade das vendas das luminárias de emergência LED.

No correlograma da série cronológica a seguir apresentado, pode confirmar-se as acima referidas características da amostra:




Ilustração 13 – Correlograma da série cronológica

O passo seguinte neste processo será verificar se a série cronológica é estacionária, e para tal, recorreremos a dois dos testes mais populares: o teste ADF (Aumentado Dickey-Fuller) e do teste KPSS (Kwiatkowski-Phillips-Schmidt-Shin). Para o teste ADF a hipótese nula é rejeitada, considerando-se assim que a série é estacionária se para um nível de significância de 5% a probabilidade do teste for menor que 0,05. Para o teste KPSS a série é estacionária se o valor do teste for inferior aos valores críticos para os habituais níveis de significância.

Null Hypothesis: LED has a unit root Exogenous: Constant, Linear Trend Lag Length: 9 (Automatic - based on SIC, maxlag=9)				
			t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic			-3.982364	0.0179
Test critical values:				
	1% level		-4.219126	
	5% level		-3.533083	
	10% level		-3.198312	
*MacKinnon (1996) one-sided p-values.				
Augmented Dickey-Fuller Test Equation Dependent Variable: D(LED) Method: Least Squares Date: 04/15/13 Time: 23:36 Sample (adjusted): 2008M11 2011M12 Included observations: 38 after adjustments				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
LED(-1)	-3.593914	0.902457	-3.982364	0.0005
D(LED(-1))	2.667382	0.866404	3.078681	0.0049
D(LED(-2))	1.841073	0.812977	2.264607	0.0321
D(LED(-3))	2.012121	0.760852	2.644664	0.0137
D(LED(-4))	1.343513	0.864273	2.022534	0.0535
D(LED(-5))	1.738987	0.584802	2.989689	0.0083
D(LED(-6))	1.047350	0.461435	2.269766	0.0317
D(LED(-7))	1.477903	0.360776	4.096453	0.0004
D(LED(-8))	0.718889	0.234320	3.067853	0.0050
D(LED(-9))	0.965789	0.162078	5.958796	0.0000
C	15328.49	4936.348	3.105230	0.0048
@TREND(2008M01)	598.8791	169.0922	3.541730	0.0015
R-squared	0.898731	Mean dependent var		1177.632
Adjusted R-squared	0.855886	S.D. dependent var		17483.67
S.E. of regression	6637.217	Akaike info criterion		20.69086
Sum squared resid	1.15E+09	Schwarz criterion		21.20800
Log likelihood	-381.1284	Hannan-Quinn criter.		20.87485
F-statistic	20.97644	Durbin-Watson stat		1.106509
Prob(F-statistic)	0.000000			

Ilustração 14 - Teste ADF à série cronológica

Null Hypothesis: LED is stationary
 Exogenous: Constant, Linear Trend
 Bandwidth: 47 (Newey-West automatic) using Bartlett kernel

	LM-Stat
Kwiatkowski-Phillips-Schmidt-Shin test statistic	0.500000
Asymptotic critical values*:	
1% level	0.216000
5% level	0.146000
10% level	0.119000

*Kwiatkowski-Phillips-Schmidt-Shin (1992, Table 1)

Residual variance (no correction)	1.24E+08
HAC corrected variance (Bartlett kernel)	10767201

KPSS Test Equation
 Dependent Variable: LED
 Method: Least Squares
 Date: 04/28/13 Time: 03:46
 Sample: 2008M01 2011M12
 Included observations: 48

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	2900.935	3237.585	0.896018	0.3749
@TREND(2008M01)	273.0542	118.6823	2.300714	0.0260

R-squared	0.103196	Mean dependent var	9317.708
Adjusted R-squared	0.083701	S.D. dependent var	11899.93
S.E. of regression	11391.03	Akaike info criterion	21.55981
Sum squared resid	5.97E+09	Schwarz criterion	21.63778
Log likelihood	-515.4355	Hannan-Quinn criter.	21.58928
F-statistic	5.293286	Durbin-Watson stat	1.981593
Prob(F-statistic)	0.025992		

Ilustração 15 – Teste KPSS da série cronológica

Os valores estatísticos do teste do ADF ($\text{Prob} = 0,0179 < 0,05$) não se encontram na zona de rejeição, pelo que se rejeita a hipótese nula. No teste KPSS, a hipótese nula é rejeitada, uma vez que o valor do teste é superior aos valores críticos para os habituais níveis de significância. Logo a série não é estacionária.

Assim, avançamos para o terceiro passo, dedicado à estacionarização da série cronológica através das transformações de estabilização da variância, eliminação da tendência (diferenciação não sazonal) e a eliminação de movimentos de carácter periódico (diferenciação sazonal).

Segue um novo teste de estacionariedade (ADF e KPSS) da nova variável, já com o efeito das várias diferenciações da série.

Previsão de Vendas da Gama de Emergência LED da ETAP.Schröder

Null Hypothesis: DIFLOGLED2 has a unit root
 Exogenous: Constant, Linear Trend
 Lag Length: 0 (Automatic - based on SIC, maxlag=8)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-7.134143	0.0000
Test critical values:		
1% level	-4.252879	
5% level	-3.548490	
10% level	-3.207094	

*Mackinnon (1996) one-sided p-values.

Augmented Dickey-Fuller Test Equation
 Dependent Variable: D(DIFLOGLED2)
 Method: Least Squares
 Date: 04/28/13 Time: 04:15
 Sample (adjusted): 2009M03 2011M12
 Included observations: 34 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
DIFLOGLED2(-1)	-1.248053	0.174941	-7.134143	0.0000
C	-0.290540	0.450859	-0.644414	0.5240
@TREND(2008M01)	0.008087	0.014066	0.574953	0.5695
R-squared	0.621524	Mean dependent var		-0.014998
Adjusted R-squared	0.597106	S.D. dependent var		1.261912
S.E. of regression	0.800985	Akaike info criterion		2.478148
Sum squared resid	19.88888	Schwarz criterion		2.612827
Log likelihood	-39.12852	Hannan-Quinn criter.		2.524077
F-statistic	25.45373	Durbin-Watson stat		2.010214
Prob(F-statistic)	0.000000			

Ilustração 16 - Teste ADF da variável corrigida

Null Hypothesis: DIFLOGLED2 is stationary
 Exogenous: Constant
 Bandwidth: 14 (Newey-West automatic) using Bartlett kernel

	LM-Stat.
Kwiatkowski-Phillips-Schmidt-Shin test statistic	0.232455
Asymptotic critical values*:	
1% level	0.739000
5% level	0.463000
10% level	0.347000

*Kwiatkowski-Phillips-Schmidt-Shin (1992, Table 1)

Residual variance (no correction)	0.609069
HAC corrected variance (Bartlett kernel)	0.119788

KPSS Test Equation
 Dependent Variable: DIFLOGLED2
 Method: Least Squares
 Date: 04/28/13 Time: 04:16
 Sample (adjusted): 2009M02 2011M12
 Included observations: 35 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	-0.034759	0.133842	-0.259703	0.7967
R-squared	0.000000	Mean dependent var		-0.034759
Adjusted R-squared	0.000000	S.D. dependent var		0.791822
S.E. of regression	0.791822	Akaike info criterion		2.399196
Sum squared resid	21.31742	Schwarz criterion		2.443635
Log likelihood	-40.98593	Hannan-Quinn criter.		2.414536
Durbin-Watson stat	2.465476			

Ilustração 17 - Teste KPSS da variável corrigida

Como demonstra a ilustração 16, os valores do teste ADF encontram-se na zona de rejeição pelo que a hipótese nula é rejeitada. No teste KPSS (ilustração 17), a hipótese nula não é rejeitada, já que o valor do teste é inferior aos valores dos habituais níveis de significância. Assim, os resultados dos testes de estacionariedade são validados, concluindo-se que a variável é estacionária.

Para o último passo, observa-se então a correlação desta nova amostra para identificar o valor de q e p, para os MA(q) e AR(p), obtendo assim este *output* do *EViews*:




Ilustração 17 – Correlação da variável corrigida

Na ilustração acima, verifica-se que nenhum valor é estritamente significativo, pelo que atribuímos no MA(q), o valor de 1 e 2 a q. O mesmo acontece para p, em AR(p). Estes valores foram atribuídos desta forma uma vez que a partir da lag 3, a ACF e a PACF registam uma queda para zero. Estimados estes quatro modelos, o que apresentar a menor RMSE, deverá ser o modelo selecionado para elaborar a previsão.

Os resultados obtidos da aplicação do modelo ARIMA estão resumidos na tabela seguinte:

Métodos		MA (1)	MA (2)	AR (1)	AR 2)
C	coef.	-0,02	0,00	-0,03	0,00
	P value	0,72	0,99	0,75	0,94
MA(1)	coef.	-0,52	-0,41		
	P value	0,00	0,00		
MA(2)	coef.		-0,57		
	P value		0,00		
AR(1)	coef.			-0,23	-0,29
	P value			0,17	0,09
AR(2)	coef.				-0,25
	P value				0,13
F-test		4,33	5,10	1,91	2,17
Significância F		0,04	0,01	0,17	0,13
AIC		2,33	2,23	2,42	2,34
SIC		2,42	2,36	2,51	2,48
R ² Ajustado		0,08	0,19	0,02	0,06
RMSE		0,75	0,71	0,79	0,74

Tabela 5 – Resumo dos valores do método ARIMA

Desta tabela, conclui-se que o método que apresenta RMSE mais baixo é o MA(2). Este método também apresenta a menor variância residual, ou seja, AIC (Akaike Info Criterion) e SIC (Schwarz Info Criterion) mais baixos, razão pela qual a escolha para a previsão deverá recair sobre este método.

Para uma melhor avaliação do modelo a escolher, é importante verificar a qualidade do ajuste do modelo através da análise dos correspondentes resíduos.

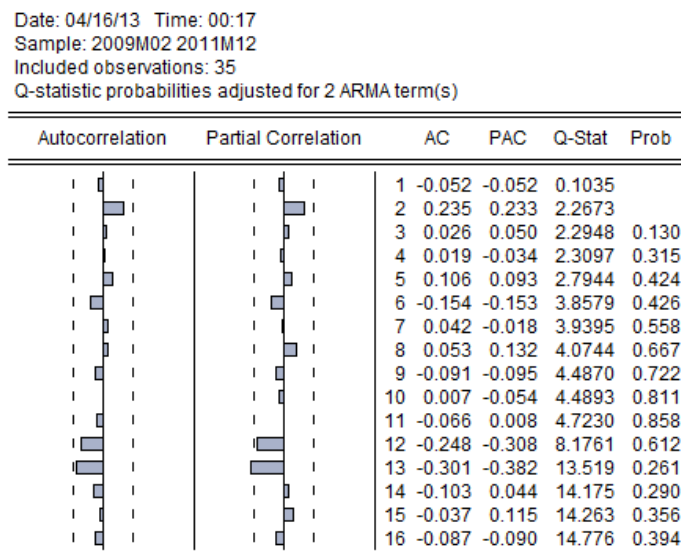


Ilustração 19 – Resíduos do modelo ARIMA MA (2)

Para melhor avaliação da qualidade do ajustamento, foi utilizado o teste Ljung – Box. Este define que um modelo é estatisticamente aceite se o valor de prova for superior a 10% e, quanto maior for, mais ajustado e adequado é o modelo à série temporal. Como na ilustração acima o $\text{Prob} > 0,05$, não se rejeita a hipótese nula. Conclui-se então que os resíduos do modelo são aleatórios e constituem um processo de “ruído branco”.

Finalizada a etapa de apuramento dos melhores métodos dentro de cada modelo, procede-se no capítulo seguinte à comparação dos melhores métodos apurados com o intuito de identificar o que melhor representa a amostra inicial.

5. FERRAMENTA DE PREVISÃO

Relembrando os melhores métodos apurados no capítulo anterior, listamos os seguintes:

- Método de Holt-Winters multiplicativo
- Método de regressão quadrática com *dummies*
- Modelo ARIMA – MA(2)

Apresenta-se de seguida a previsão do método de Holt-Winters para o ano de 2012. Os valores da tabela abaixo foram extraídos do ficheiro de previsão gerado pelo *software EViews*.

Mês 2012	Holt-Winters
Janeiro	16.249,29
Fevereiro	16.653,72
Março	17.058,14
Abril	17.462,56
Maiο	17.866,99
Junho	18.271,41
Julho	18.675,83
Agosto	19.080,26
Setembro	19.484,68
Outubro	19.889,10
Novembro	20.293,53
Dezembro	20.697,95

Tabela 6 – Previsão para o ano de 2012 do método de Holt-Winters multiplicativo

Também com base no ficheiro de previsão gerado pelo *software EViews* para o método de regressão quadrática com *dummies*, foi criada a seguinte tabela de previsão para o ano de 2012:

Mês 2012	Regressão
Janeiro	7.055,57
Fevereiro	8.441,72
Março	17.177,88
Abril	11.914,03
Maio	13.400,19
Junho	17.386,34
Julho	35.122,49
Agosto	10.058,65
Setembro	12.794,80
Outubro	17.380,95
Novembro	22.467,10
Dezembro	51.903,26

Tabela 7 – Previsão para o ano de 2012 do modelo de regressão quadrática com *dummies*

Por último, gerado o ficheiro de previsão do modelo ARIMA - MA(2) , obtém-se os seguintes valores para 2012:

Mês 2012	ARIMA
Janeiro	2.661,16
Fevereiro	4.192,03
Março	19.498,05
Abril	3.687,38
Maio	9.218,77
Junho	15.672,46
Julho	37.160,38
Agosto	1.843,94
Setembro	3.688,02
Outubro	23.972,97
Novembro	26.103,45
Dezembro	81.287,98

Tabela 8 – Previsão para o ano de 2012 do modelo ARIMA - MA(2)

Concluídos os cálculos para todos os modelos pré-selecionados, passa-se à apresentação do comparativo de previsões de vendas para 2012 na tabela seguinte.

Previsão de Vendas da Gama de Emergência LED da ETAP.Schröder

Mês 2012	Amostra	Holt-Winters	Erros Holt-Winters	Regressão	Erros Regressão	ARIMA	Erros ARIMA
Janeiro	3.500,00	16.249,29	162.544.395,50	7.055,57	12.642.078,02	2.661,16	703.652,55
Fevereiro	4.000,00	16.653,72	160.116.629,84	8.441,72	19.728.876,56	4.192,03	36.875,52
Março	21.500,00	17.058,14	19.730.120,26	17.177,88	18.680.721,29	19.498,05	4.007.803,80
Abril	7.250,00	17.462,56	104.296.381,75	11.914,03	21.753.175,84	3.687,38	12.692.261,26
Mai	13.500,00	17.866,99	19.070.601,66	13.400,19	9.962,04	9.218,77	18.328.930,31
Junho	19.750,00	18.271,41	2.186.228,39	17.386,34	5.586.888,60	15.672,46	16.626.332,45
Julho	24.750,00	18.675,83	36.895.541,19	35.122,49	107.588.548,80	37.160,38	154.017.531,74
Agosto	5.500,00	19.080,26	184.423.461,67	10.058,65	20.781.289,82	1.843,94	13.366.774,72
Setembro	9.250,00	19.484,68	104.748.674,70	12.794,80	12.565.607,04	3.688,02	30.935.621,52
Outubro	14.000,00	19.889,10	34.681.498,81	17.380,95	11.430.822,90	23.972,97	99.460.130,62
Novembro	22.000,00	20.293,53	2.912.039,86	22.467,10	218.182,41	26.103,45	16.838.301,90
Dezembro	71.000,00	20.697,95	2.530.296.234,20	51.903,26	364.685.478,63	81.287,98	105.842.532,48
Soma Erros			3.361.901.807,84		595.671.631,95		472.856.748,89
RMSE			16.737,94		7.045,52		6.277,32

Tabela 9 – Comparação da previsão dos modelos

Na análise dos dados da tabela, pode verificar-se que o método multiplicativo de Holt-Winters apresenta previsões com fraco índice de sazonalidade, em comparação com os outros métodos utilizados. Este método é também o que revela resultados com maior soma de erros.

Regista-se ainda que o método de regressão linear quadrática com *dummies* tem um comportamento relativamente semelhante à amostra, ainda que com maior soma de erros quando comparada com a previsão do método ARIMA. No que respeita à sazonalidade, este modelo apresenta um melhor desempenho nas previsões que os métodos alvo desta análise comparativa.

Relembrando o acima definido critério fundamental para a escolha do melhor método de previsão: menor valor de RMSE, conclui-se que o modelo com valor de RMSE mais reduzido - entre os modelos comparados - é o ARIMA MA(2), o que o torna o mais adequado modelo de previsão para a série cronológica inicial.

Com base nesta evidência, apresentam-se de seguida as conclusões deste estudo.

6. CONCLUSÕES

6.1. CONTRIBUTOS DO PROJETO

O projeto aqui desenvolvido enquadra-se na problemática da previsão de vendas, contribuindo com um estudo que permite minimizar o problema de disponibilidade de stock, associado à necessidade de curtos prazos de entrega da iluminação de emergência LED da ETAP.

Neste estudo foram analisados vários modelos de previsão, tendo como critério de seleção do melhor método de previsão o menor erro RMSE. Foi possível retirar conclusões da aplicação dos vários métodos aplicados, tal como é apresentado de seguida.

No método Holt-Winters foram testadas as seguintes tendências lineares: sem sazonalidade e com sazonalidade (aditivo e multiplicativo). Os melhores resultados (menor erro RMSE) foram identificados na tendência linear multiplicativa, que registou também o melhor desempenho ao nível da sazonalidade em relação à amostra inicial.

O modelo de regressão linear múltipla foi testado nos seguintes métodos: regressão linear, regressão quadrática, regressão linear com *dummies* e regressão quadrática com *dummies*. Da análise destes métodos concluiu-se que a regressão quadrática com *dummies* apresentou os melhores resultados muito por conta da função quadrática e da incorporação do fator da sazonalidade mensal através das *dummies*. Salienta-se ainda que este método teve um bom desempenho ao nível do erro RMSE registado.

O modelo ARIMA foi trabalhado com base em 4 diferentes funções: MA(1), MA(2), AR(1) e AR(2). A função MA(2) foi a que apresentou resultados mais próximos da amostra inicial. Este desempenho fica a dever-se à função ACF que registou uma queda brusca para zero a partir do *lag* 3.

No comparativo dos 3 métodos, o modelo atrás selecionado – ARIMA de médias móveis de 2ª ordem - demonstrou ser o que melhor se ajusta às 3 características

fundamentais da série cronológica inicial: sazonalidade, tendência e a irregularidade. Pode assim afirmar-se que este modelo segue o padrão real.

Este trabalho permitiu então encontrar um modelo de cálculo para a gestão de encomendas e previsão de vendas de luminárias de emergência LED, inexistente anteriormente, proporcionando no futuro a concretização de negócios até aqui perdidos por indisponibilidade de stock.

Este estudo, vislumbra-se, permitirá ser uma sólida base para a aplicação de semelhante metodologia ou ferramenta em relação a outros mercados onde a empresa opera recentemente: Angola e Moçambique. Aproveitando a mesma abordagem metódica e científica será possível ir mais além e com maior rigor no âmbito das previsões de vendas, uma vez que atualmente a empresa se baseia fundamentalmente em métodos meramente qualitativos para calcular as necessidades de stock disponível.

6.2. LIMITAÇÕES

O presente estudo deparou-se, no entanto, com algumas limitações que influenciam o seu resultado final.

Identifica-se que nos dados recolhidos pesa o elevado volume de vendas associado a algumas obras com carácter pontual, o que, não dispondo dessa informação mais detalhada pode resultar em alguns desajustes na previsão. Idealmente seria vantajoso considerar a informação destas grandes obras com uma variável explicativa de modo a testar a sua correlação com o valor da série de vendas.

Por fim, a inexistência de estudos científicos prévios na área da iluminação - quer na área de previsão de vendas, quer no âmbito da gestão de stocks - representa um empobrecimento do substrato teórico que fundamenta este estudo.

7. BIBLIOGRAFIA

Monografia (Livros):

CAIADO, J. (2011). *Métodos de Previsão para a Gestão com Aplicações em Excel* (1ª Edição), Lisboa: Edições Sílabo.

Justino, L. (2007), *Direcção Comercial* (2ª Edição), Lisboa: Lidel.

Jobber, D., Lancaster, G.(2012), *Selling and Sales Management* (9ª Edição), Canada: Pearson.

Lopes dos Reis (2008), *Estratégia Empresarial* (2ª Edição), Lisboa : Editorial Presença.

Richard,L. (2006), *Corporate Strategy* (4ª Edição), Edinburg: Prentice Hall.

Volgelvang,B.(2005), *Theory and Applications with EViews* (1ª Edição), Edinburg: Prentice Hall.

Contribuições para o trabalho colectivo:

Dias Curto, J. (2010), Métodos Quantitativos Aplicados à Direcção Comercial, *Mestrado Executivo em Direcção Comercial (Sales Management)*.

Periódicos Científicos:

Alison-Koerber, D&Wilson, J. (1992), Combining subjective and objective forecasts improve results, *The Journal of the Operational Research*, 58(11), 1449-1469.

Cuddington,J. (2011), Integrating Financial Statement Modeling and Sales Forecasting, *Journal of Applied Business and Economics* 12, 6, 100-120.

Eyck, J. (2000), Forecasting with excel, *The Journal of Business Forecasting*, 19 (2), 22-27.

Fliedner, G. (2001), Hierarchical forecasting: issues and use guidelines, *Industrial Management + Data Systems*, 101 (1), 5-12.

Geurts, D., Whitlark,D. (1996), Impriving sales forecast by improving the input data, *The Journal of Business Forecasting Methods & Systems*, 15 (3), 15.

Jain, C. (2007), Benchmarking forecasting models, *The journal of Business Forecasting*, 25(4), 14-17.

Suominen, A., Seppänen, M. (2011), Setting the upper bound of growth in trend extrapolations, *International Assciation for Management of Tecnology*, 1-6.

Teses:

Garcia Mamede, M. (2012), *Previsão de Vendas na Distribuição de Produtos Percíveis*, Projecto em Mestrado em Gestão, ISCTE.

Hong, T (2010), *Short Term Electric Load Forecasting*, A dissertation submitted to the Graduate Faculty of North Carolina State University in partial fulfillment of the requirements for the degree of Doctor of Philosophy.

Páginas de Internet:

<http://www.etaplighting.com>

<http://www.celma.org>

8. ANEXOS

ANEXO 1 – Amostra da série temporal

Fonte dos dados: ETAP.Schröder

Mês	2008	2009	2010	2011	2012
Janeiro	250,00	1000,00	750,00	500,00	3500,00
Fevereiro	750,00	3250,00	1500,00	1750,00	4000,00
Março	8000,00	8250,00	2500,00	13000,00	21500,00
Abril	1000,00	3750,00	4250,00	9000,00	7250,00
Maiο	2500,00	4750,00	2750,00	7500,00	13500,00
Junho	4250,00	5750,00	7500,00	12000,00	19750,00
Julho	15500,00	18750,00	32250,00	45000,00	24750,00
Agosto	500,00	1500,00	750,00	1000,00	5500,00
Setembro	1000,00	7250,00	1500,00	2250,00	9250,00
Outubro	6500,00	11250,00	3500,00	7250,00	14000,00
Novembro	12500,00	12000,00	7000,00	12750,00	22000,00
Dezembro	24750,00	21500,00	43250,00	51250,00	71000,00

Tabela 10 – Vendas em valor da iluminação de emergência LED

Outputs do método de Holt –Winters no *software EViews*:

```

Date: 04/27/13 Time: 14:13
Sample: 2008M01 2011M12
Included observations: 48
Method: Holt-Winters No Seasonal
Original Series: LED
Forecast Series: LEDSM

```

Parameters:	Alpha	0.0300
	Beta	0.1600
	Sum of Squared Residuals	6.43E+09
	Root Mean Squared Error	11576.63

End of Period Levels:	Mean	15844.87
	Trend	404.4233

Ilustração 20 – Método de Holt-Winters sem sazonalidade

Date: 04/27/13 Time: 14:43
 Sample: 2008M01 2011M12
 Included observations: 48
 Method: Holt-Winters Additive Seasonal
 Original Series: LED
 Forecast Series: LEDSM

Parameters:	Alpha	0.0000
	Beta	0.0000
	Gamma	0.0000
	Sum of Squared Residuals	1.12E+09
	Root Mean Squared Error	4830.790

End of Period Levels:	Mean	14695.89
	Trend	198.4954
	Seasonals:	
	2011M01	-7600.984
	2011M02	-6611.979
	2011M03	-685.4745
	2011M04	-4321.470
	2011M05	-4644.965
	2011M06	-1843.461
	2011M07	18458.04
	2011M08	-8677.951
	2011M09	-6813.947
	2011M10	-2887.442
	2011M11	851.5625
	2011M12	24778.07

Ilustração 21 – Método de Holt-Winters aditivo

Date: 04/27/13 Time: 14:58
 Sample: 2008M01 2011M12
 Included observations: 48
 Method: Holt-Winters Multiplicative Seasonal
 Original Series: LED
 Forecast Series: LEDSM

Parameters:	Alpha	0.0000
	Beta	0.0000
	Gamma	0.0000
	Sum of Squared Residuals	5.64E+08
	Root Mean Squared Error	3426.385

End of Period Levels:	Mean	14695.89
	Trend	198.4954
	Seasonals:	
	2011M01	0.083889
	2011M02	0.234829
	2011M03	0.988545
	2011M04	0.480042
	2011M05	0.491540
	2011M06	0.811008
	2011M07	2.987868
	2011M08	0.104985
	2011M09	0.336759
	2011M10	0.791989
	2011M11	1.200694
	2011M12	3.487852

Ilustração 22 – Método de Holt-Winters multiplicativo

Outputs do método de regressão linear no *software EViews*:

Dependent Variable: LED
 Method: Least Squares
 Date: 04/28/13 Time: 00:03
 Sample: 2008M01 2011M12
 Included observations: 48

Variable	Coefficient	Std. Error	t-Statistic	Prob.
T	273.0542	118.6823	2.300714	0.0260
C	2627.881	3340.369	0.786704	0.4355

R-squared	0.103196	Mean dependent var	9317.708
Adjusted R-squared	0.083701	S.D. dependent var	11899.93
S.E. of regression	11391.03	Akaike info criterion	21.55981
Sum squared resid	5.97E+09	Schwarz criterion	21.63778
Log likelihood	-515.4355	Hannan-Quinn criter.	21.58928
F-statistic	5.293286	Durbin-Watson stat	1.981593
Prob(F-statistic)	0.025992		

Ilustração 23 – Método de regressão linear

Dependent Variable: LED
 Method: Least Squares
 Date: 04/28/13 Time: 01:06
 Sample: 2008M01 2011M12
 Included observations: 48

Variable	Coefficient	Std. Error	t-Statistic	Prob.
T	-114.3157	486.1202	-0.235159	0.8152
T^2	7.905508	9.618446	0.821911	0.4155
C	5855.964	5163.607	1.134084	0.2628

R-squared	0.116460	Mean dependent var	9317.708
Adjusted R-squared	0.077192	S.D. dependent var	11899.93
S.E. of regression	11431.42	Akaike info criterion	21.58658
Sum squared resid	5.88E+09	Schwarz criterion	21.70353
Log likelihood	-515.0779	Hannan-Quinn criter.	21.63078
F-statistic	2.965744	Durbin-Watson stat	2.007467
Prob(F-statistic)	0.061672		

Ilustração 24 – Método de regressão quadrática

Previsão de Vendas da Gama de Emergência LED da ETAP.Schröder

Dependent Variable: LED
 Method: Least Squares
 Date: 04/28/13 Time: 00:10
 Sample: 2008M01 2011M12
 Included observations: 48

Variable	Coefficient	Std. Error	t-Statistic	Prob.
T	184.5486	60.14846	3.068218	0.0041
JAN	-32532.47	4008.343	-8.116187	0.0000
FEV	-31529.51	3998.855	-7.884635	0.0000
MAR	-25589.06	3990.251	-6.412895	0.0000
ABR	-29211.11	3982.537	-7.334800	0.0000
MAI	-29520.66	3975.718	-7.425240	0.0000
JUN	-26705.21	3969.799	-6.727094	0.0000
JUL	-6389.757	3964.783	-1.611628	0.1160
AGO	-33511.81	3960.675	-8.461136	0.0000
SET	-31633.85	3957.476	-7.993441	0.0000
OUT	-27693.40	3955.190	-7.001788	0.0000
NOV	-23940.45	3953.818	-6.055021	0.0000
C	29651.04	3327.249	8.911580	0.0000

R-squared	0.835622	Mean dependent var	9317.708
Adjusted R-squared	0.779264	S.D. dependent var	11899.93
S.E. of regression	5590.896	Akaike info criterion	20.32148
Sum squared resid	1.09E+09	Schwarz criterion	20.82826
Log likelihood	-474.7155	Hannan-Quinn criter.	20.51299
F-statistic	14.82697	Durbin-Watson stat	1.872655
Prob(F-statistic)	0.000000		

Ilustração 25 – Método de regressão linear com *dummies*

Dependent Variable: LED
 Method: Least Squares
 Date: 04/28/13 Time: 00:19
 Sample: 2008M01 2011M12
 Included observations: 48

Variable	Coefficient	Std. Error	t-Statistic	Prob.
T	-167.5511	233.9527	-0.716175	0.4788
T^2	7.185709	4.620408	1.555211	0.1292
JAN	-32532.47	3929.496	-8.279043	0.0000
FEV	-31457.66	3920.467	-8.023957	0.0000
MAR	-25459.72	3912.643	-6.507038	0.0000
ABR	-29038.65	3905.772	-7.434806	0.0000
MAI	-29319.46	3899.659	-7.518468	0.0000
JUN	-26489.64	3894.177	-6.802371	0.0000
JUL	-6174.186	3889.263	-1.587495	0.1217
AGO	-33310.61	3884.920	-8.574336	0.0000
SET	-31461.40	3881.214	-8.106071	0.0000
OUT	-27564.06	3878.280	-7.107290	0.0000
NOV	-23868.59	3876.318	-6.157542	0.0000
C	32453.47	3726.444	8.708963	0.0000

R-squared	0.846539	Mean dependent var	9317.708
Adjusted R-squared	0.787862	S.D. dependent var	11899.93
S.E. of regression	5480.918	Akaike info criterion	20.29443
Sum squared resid	1.02E+09	Schwarz criterion	20.84019
Log likelihood	-473.0662	Hannan-Quinn criter.	20.50067
F-statistic	14.42725	Durbin-Watson stat	1.996936
Prob(F-statistic)	0.000000		

Ilustração 26 – Método de regressão quadrática com *dummies*

Outputs do método ARIMA no *software EViews*:

Dependent Variable: DLOG(LED,1,12)
 Method: Least Squares
 Date: 04/28/13 Time: 04:44
 Sample (adjusted): 2009M02 2011M12
 Included observations: 35 after adjustments
 Convergence achieved after 9 iterations
 MA Backcast: 2009M01

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	-0.022154	0.062877	-0.352331	0.7268
MA(1)	-0.525688	0.147070	-3.574399	0.0011
R-squared	0.116044	Mean dependent var		-0.034759
Adjusted R-squared	0.089258	S.D. dependent var		0.791822
S.E. of regression	0.755659	Akaike info criterion		2.332991
Sum squared resid	18.84365	Schwarz criterion		2.421868
Log likelihood	-38.82734	Hannan-Quinn criter.		2.363671
F-statistic	4.332184	Durbin-Watson stat		1.722315
Prob(F-statistic)	0.045233			
Inverted MA Roots	.53			

Ilustração 27 – Estimação do modelo ARIMA – MA(1)

Dependent Variable: DLOG(LED,1,12)
 Method: Least Squares
 Date: 04/15/13 Time: 00:44
 Sample (adjusted): 2009M02 2011M12
 Included observations: 35 after adjustments
 Convergence achieved after 14 iterations
 MA Backcast: 2008M12 2009M01

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	-6.18E-05	0.021485	-0.002878	0.9977
MA(1)	-0.419842	0.143791	-2.919813	0.0064
MA(2)	-0.579660	0.139916	-4.142922	0.0002
R-squared	0.241863	Mean dependent var		-0.034759
Adjusted R-squared	0.194480	S.D. dependent var		0.791822
S.E. of regression	0.710667	Akaike info criterion		2.236590
Sum squared resid	16.16151	Schwarz criterion		2.369906
Log likelihood	-36.14033	Hannan-Quinn criter.		2.282611
F-statistic	5.104378	Durbin-Watson stat		2.076325
Prob(F-statistic)	0.011911			
Inverted MA Roots	1.00	-.58		

Ilustração 28 – Estimação do modelo ARIMA – MA(2)

Dependent Variable: DLOG(LED,1,12)
 Method: Least Squares
 Date: 04/28/13 Time: 04:51
 Sample (adjusted): 2009M03 2011M12
 Included observations: 34 after adjustments
 Convergence achieved after 3 iterations

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	-0.035248	0.109766	-0.321120	0.7502
AR(1)	-0.238445	0.172310	-1.383814	0.1760
R-squared	0.056463	Mean dependent var		-0.038136
Adjusted R-squared	0.026978	S.D. dependent var		0.803474
S.E. of regression	0.792562	Akaike info criterion		2.429932
Sum squared resid	20.10097	Schwarz criterion		2.519717
Log likelihood	-39.30884	Hannan-Quinn criter.		2.460551
F-statistic	1.914942	Durbin-Watson stat		2.003469
Prob(F-statistic)	0.175992			
Inverted AR Roots	-0.24			

Ilustração 29 – Estimação do modelo ARIMA – AR(1)

Dependent Variable: DLOG(LED,1,12)
 Method: Least Squares
 Date: 04/15/13 Time: 00:47
 Sample (adjusted): 2009M04 2011M12
 Included observations: 33 after adjustments
 Convergence achieved after 3 iterations

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	-0.005555	0.084219	-0.065959	0.9478
AR(1)	-0.293283	0.167891	-1.746866	0.0909
AR(2)	-0.256627	0.167893	-1.528517	0.1369
R-squared	0.126770	Mean dependent var		0.004211
Adjusted R-squared	0.068555	S.D. dependent var		0.776448
S.E. of regression	0.749360	Akaike info criterion		2.347315
Sum squared resid	16.84623	Schwarz criterion		2.483361
Log likelihood	-35.73069	Hannan-Quinn criter.		2.393090
F-statistic	2.177607	Durbin-Watson stat		1.867098
Prob(F-statistic)	0.130897			
Inverted AR Roots	-0.15+0.48i	-0.15-0.48i		

Ilustração 30 – Estimação do modelo ARIMA – AR(2)