

Previsão de vendas numa empresa de distribuição farmacêutica: uma aproximação baseada em *data mining*

Sales prediction for a pharmaceutical distribution company: a data mining based approach

Augusto Ribeiro

Departamento de Informática
OCP Portugal
Maia, Portugal
acarlosrib@gmail.com

Isabel Seruca

Departamento de Economia, Gestão
e Informática, Universidade
Portucalense;
Centro Algoritmi, Universidade do
Minho
Porto, Portugal; Guimarães, Portugal
iseruca@upt.pt

Natércia Durão

Departamento de Economia, Gestão
e Informática, Universidade
Portucalense
Porto, Portugal
natercia@upt.pt

Resumo — Para as empresas de distribuição farmacêutica é essencial conseguir obter uma boa previsão das necessidades de medicamentos, devido ao curto prazo de validade de muitos medicamentos e à necessidade de controlar os níveis de *stock*, de forma a evitar custos excessivos de *stock* e simultaneamente a perda de clientes devido a falhas de *stock*.

Neste trabalho explora-se a utilização da técnica de *data mining* de séries temporais para a previsão de vendas de produtos ao nível individual (produto a produto), de uma empresa de distribuição farmacêutica em Portugal. Através de técnicas de *data mining*, os dados históricos das vendas de produtos são explorados para detetar padrões e fazer previsões a partir da experiência contida nos dados. Os resultados obtidos com a técnica e o método propostos indicam que a modelação efetuada pode ser considerada adequada para a previsão de vendas de produtos no curto prazo.

Palavras Chave – *medicamentos; rutura stock; data mining; séries temporais; previsão de vendas.*

Abstract — For pharmaceutical distribution companies it is essential to obtain good estimates of medicine needs, due to the short shelf life of many medicines and the need to control stock levels, so as to avoid excessive inventory costs while guaranteeing customer demand satisfaction, and thus decreasing the possibility of loss of customers due to stock outages.

In this paper we explore the use of the time series data mining technique for the sales prediction of individual products of a pharmaceutical distribution company in Portugal. Through data mining techniques, the historical data of product sales are analyzed to detect patterns and make predictions based on the experience contained in the data. The results obtained with the technique as well as with the proposed method suggest that the performed modelling may be considered appropriate for the short term product sales prediction.

Keywords – *medicines; stock unavailability; data mining; time series; sales prediction.*

I. INTRODUÇÃO

Uma das responsabilidades dos distribuidores grossistas de medicamentos em Portugal é serem obrigados por lei a ter um *stock* mínimo de medicamentos, de modo a garantir o abastecimento no mercado nacional e, desta forma, evitar possíveis situações de rutura nas farmácias.

Para além deste requisito legal, as distribuidoras farmacêuticas necessitam de obter uma boa previsão das necessidades de medicamentos, devido ao curto prazo de validade de muitos medicamentos e à necessidade de controlar os níveis de *stock*, de forma a evitar custos excessivos e simultaneamente a perda de clientes devido a falhas de *stock*.

Uma boa previsão de vendas está, geralmente, associada a conseguir obter um bom equilíbrio entre os custos de *stock* e uma adequada satisfação da procura dos clientes [1]. Para o caso específico da indústria de distribuição farmacêutica, o problema adquire particular importância devido ao curto ciclo de vida de muitos dos produtos e da importância da qualidade dos produtos que está, por sua vez, fortemente ligada a aspetos de saúde pública [2] [3].

Frequentemente, as empresas não endereçam de uma forma adequada o problema da previsão de vendas ou utilizam processos simples de determinação de quantidades a comprar de um determinado produto para o mês seguinte, com base no cálculo da média aritmética das quantidades vendidas desse produto num determinado período histórico de tempo, por exemplo, nos últimos 12 meses.

Tendo em conta estas dificuldades, este artigo explora a utilização da técnica de *data mining* de séries temporais para a

previsão de vendas de produtos ao nível individual de uma empresa de distribuição farmacêutica em Portugal. Foi efetuada a previsão de vendas para 357 medicamentos comercializados pela empresa de distribuição farmacêutica. A previsão de vendas foi feita com base na análise de um histórico de dados de 24 meses e para um horizonte temporal de 3 meses. O método de data mining de séries temporais Pegels amortecido foi utilizado no cálculo da previsão de vendas e a implementação foi feita em SQL, estando os dados a analisar armazenados numa base de dados ORACLE.

Este artigo está estruturado da seguinte forma: a Secção II visa a caracterização dos conceitos essenciais associados à atividade de data mining, incluindo uma panorâmica das categorias e a descrição dos principais métodos associados à técnica de séries temporais da categoria de data mining preditivo. Na Secção III é apresentada a previsão de vendas efetuada para a empresa, enquadrando-se o problema e apresentando-se a fundamentação para o método de data mining utilizado. São ainda apresentados e interpretados os resultados obtidos. Por último, na Secção IV são apresentadas algumas considerações finais e propostas de trabalho futuro.

II. DATA MINING

O *data mining*, designação em inglês amplamente utilizada para a prospeção ou mineração de dados, consiste na procura de relacionamentos, padrões ou modelos que estão implícitos nos dados armazenados em grandes bases de dados [4].

O *data mining* pode, assim, ser encarado como o processo de explorar grandes quantidades de dados com vista à identificação de padrões consistentes, como regras de associação ou sequências temporais, para detetar relacionamentos sistemáticos entre variáveis. Utiliza algoritmos para descobrir regras, identificar fatores e tendências-chave, descobrir padrões e relacionamentos ocultos em grandes bases de dados; essa informação, depois de interpretada, é utilizada no suporte à tomada de decisão organizacional.

A informação resultante do processo de data mining pode e deve ser utilizada na melhoria de procedimentos, tornando a organização proactiva e, por isso, mais competitiva. Esta melhoria resulta da identificação de padrões e comportamentos, permitindo assim à organização tomar medidas corretivas em relação a ações correntes e antever posicionamentos futuros mais competitivos face ao mercado.

O *data mining* é uma prática relativamente recente no mundo da computação, aplica-se em várias áreas e setores de negócio e utiliza técnicas de recuperação de informação, inteligência artificial, reconhecimento de padrões e de estatística. Sendo um processo de descoberta de informação de carácter eminentemente preditivo e estratégico em grandes quantidades de dados, é um processo largamente automatizado que atua não só descrevendo factos do passado e presente, mas também para antever tendências futuras, originando conhecimento que se pode traduzir em importantes vantagens competitivas [5] [6].

A. Categorias de Data Mining

As atividades associadas ao *data mining* podem ser divididas em dois grupos: descrição ou previsão. No *data mining*

descritivo identificam-se regras que caracterizam os dados analisados. Por outro lado, no *data mining* preditivo utilizam-se determinados atributos da base de dados ou conjunto de dados para prever o valor desconhecido ou futuro de uma outra variável de interesse.

Esta distinção está associada ao objetivo da atividade de *data mining*, que pode permitir aumentar o conhecimento acerca dos dados, descrição, ou suportar o processo de tomada de decisão, previsão, através de modelos capazes de prever o valor de uma variável [7].

Um exemplo de *data mining* na categoria descritiva é a determinação dos perfis de compras dos clientes de uma organização para criação de campanhas de marketing direcionadas, com base na análise da base de dados das transações dos clientes. Um exemplo de *data mining* na categoria de previsão é a previsão de vendas de um produto em termos futuros, para uma melhor gestão de *stocks*, com base na análise do histórico de vendas desse produto.

Relativamente à previsão, o melhor modelo é aquele que apresenta a precisão mais elevada, permitindo uma percentagem de acerto superior à percentagem de acerto conseguida por outros modelos, ainda que estes tenham sido mais fáceis de obter e de perceber. Por outro lado, o melhor modelo em descrição pode não ser aquele que obtém resultados mais precisos em termos de confiança do modelo, mas sim o que permite um conhecimento mais alargado dos dados analisados.

Cada uma das categorias de data mining identificadas (descrição e previsão) inclui um conjunto de métodos que deverão ser utilizados tendo em conta a natureza do problema a resolver.

B. Data Mining preditivo: Modelos de séries temporais

As séries temporais podem ser vistas como um caso particular dos dados com dependência temporal. Uma série temporal $X(t)$ pode ser descrita como uma sequência de valores produzidos por um sistema e obtidos a intervalos de tempo regulares, sendo representada pela expressão:

$$X(t) = \dots, X_{t-2}, X_{t-1}, X_t, X_{t+1}, X_{t+2}, \dots$$

em que a sucessão de valores $x_{(t+i)}$ corresponde a um conjunto de valores de amostragem de uma variável específica, medida sempre nas mesmas condições mas em diferentes instantes temporais, e em que os instantes temporais que definem cada ponto de amostragem são ordenados de forma crescente.

Existem conjuntos de dados em que o atributo alvo (variável cujo valor se pretende prever) é dependente do tempo, ou seja, está associado a uma sequência consecutiva de períodos, e o interesse é conhecer essa dependência. O objetivo dos modelos de séries temporais é identificar padrões regulares de observações históricas com a finalidade de fazer previsões para o futuro. Estes modelos são usados em várias áreas nomeadamente na Gestão empresarial (previsão de procura de produtos, de consumos de eletricidade), Finanças (previsão de evoluções de mercados financeiros), Macroeconomia (previsão de crescimentos económicos, de taxas de inflação), Gestão pública (previsões de tráfego em pontes ou estradas) [5].

1) Suavização exponencial

A suavização exponencial é um método muito utilizado na produção de uma série temporal. O método considera pesos exponenciais, que diminuem conforme a antiguidade das observações. Ou seja, as observações recentes têm mais peso que as antigas para a previsão.

Na suavização exponencial, há um ou mais parâmetros de suavização a serem determinados (ou estimados) e essas escolhas determinam os pesos atribuídos às observações.

O rótulo Holt-Winters (HW) é frequentemente atribuído a um conjunto de procedimentos que formam o núcleo da família de métodos de previsão de suavização exponencial. As estruturas básicas foram fornecidas por C.C. Holt em 1957 e P. Winters em 1960 [8].

A suavização exponencial simples (*Simple exponential smoothing*) não funciona bem quando há uma tendência nos dados. As tendências de dados permitem avaliar como os dados de resposta mudam ao longo do tempo; por exemplo, pode-se criar um inquérito de satisfação de clientes durante um ano, e verificar se o número de clientes satisfeitos aumentou ou diminuiu ao longo desse ano.

Para essas situações, vários métodos foram criados sob o nome de "Suavização exponencial de segunda ordem" (*Double exponential smoothing* (Holt)), em que existe a aplicação recursiva de um filtro exponencial duas vezes, justificando, por isso, a designação "suavização exponencial dupla" (cf. Equação 1). A ideia de base inerente à suavização exponencial dupla consiste na introdução de um prazo para ter em conta a possibilidade de uma série que apresenta algum tipo de tendência. Este componente de inclinação é em si atualizado via suavização exponencial.

$$\begin{aligned} s_t &= \alpha y_t + (1 - \alpha)(s_{t-1} + m_{t-1}) \\ m_t &= \beta(s_t - s_{t-1}) + (1 - \beta) m_{t-1} \\ f_{t+1} &= s_t + m_t \end{aligned} \quad (1)$$

A "Suavização exponencial tripla" (*Triple exponential smoothing* - Holt-Winters) considera ainda uma componente adicional, a sazonalidade [9], conforme apresentado na Equação 2.

$$\begin{aligned} s_t &= \alpha \frac{y_t}{q_{t-L}} + (1 - \alpha)(s_{t-1} + m_{t-1}) \\ m_t &= \beta(s_t - s_{t-1}) + (1 - \beta) m_{t-1} \\ q_t &= \gamma \frac{y_t}{s_t} + (1 - \gamma) q_{t-L} \\ f_{t+1} &= (s_t + m_t) q_{t-L+1} \end{aligned} \quad (2)$$

em que:

t = Período de tempo corrente
 y_t = Valor atual observado no momento t
 α = Constante do processo de suavização
 β = Constante de tendência de suavização
 s_t = Valor de suavização no período t

m_t = Valor de tendência no período t
 f_{t+1} = Valor da previsão para $t+1$
 γ = Constante de sazonalidade de suavização
 L = Número de ciclos sazonais

A robustez e precisão das previsões efetuadas por suavização exponencial levou à sua ampla utilização em aplicações em que um grande número de séries necessita de um procedimento automatizado, tal como no caso do controle de *stocks*.

Embora o método de Holt tenda a ser a abordagem mais popular para a tendência da série, a sua função de previsão linear tem sido criticada pela tendência a ultrapassar os dados reais para além do curto prazo.

Gardner e McKenzie [10] resolveram este problema através da inclusão de um parâmetro extra no método de Holt para amortecer a tendência projetada. Apesar da sua popularidade, a evidência empírica tem demonstrado que a função linear de previsão Holt tende a superestimar [10]. Consequentemente, Gardner e McKenzie propõem a utilização de um parâmetro de amortecimento \emptyset no método de Holt para controlar melhor a extrapolação de tendências. Assim, o método de Holt amortecido sugerido por Gardner e McKenzie [10] é descrito pela Equação 3:

$$\begin{aligned} C_t &= \alpha X_t + (1 - \alpha)(C_{t-1} + \emptyset T_{t-1}) \\ T_t &= \beta(C_t - C_{t-1}) + (1 - \beta) \emptyset T_{t-1} \\ X_t(m) &= C_t + \sum_{i=1}^m \emptyset^i T_t \end{aligned} \quad (3)$$

em que:

t = Período de tempo corrente
 α = Constante do processo de suavização ($0 < \alpha < 1$)
 β = Constante de tendência de suavização ($0 < \beta < 1$)
 C_t = Valor de suavização no período t
 T_t = Valor de tendência no período t
 \emptyset = Constante de amortecimento ($0 < \emptyset < 1$)
 $X_t(m)$ = Valor da previsão para $t+m$

Pegels [11] sugere que o seu método multiplicativo da tendência possa ser mais útil do que o método de Holt que considera uma tendência aditiva, uma vez que a tendência multiplicativa tende a ser mais provável em aplicações da vida real.

Segundo Taylor [12], pode haver vantagem em incluir um parâmetro extra na formulação de Pegels para amortecer a tendência extrapolada, de um modo análogo ao parâmetro de amortecimento utilizado no método Holt. Assim, no método de Pegels com tendência multiplicativa, Taylor [12] sugere a inclusão de um parâmetro de amortecimento (cf. Equação 4).

$$\begin{aligned} C_t &= \alpha X_t + (1 - \alpha) (C_{t-1} T_{t-1}^\emptyset) \\ T_t &= \beta(C_t / C_{t-1}) + (1 - \beta) T_{t-1}^\emptyset \\ X_t(m) &= C_t + T_t \sum_{i=1}^m \emptyset^i \end{aligned} \quad (4)$$

em que:

t = Período de tempo corrente

α = Constante do processo de suavização ($0 < \alpha < 1$)

β = Constante de tendência de suavização ($0 < \beta < 1$)

C_t = Valor de suavização no período t

T_t = Valor de tendência no período t

\emptyset = Constante de amortecimento ($0 < \emptyset < 1$)

$X_t(m)$ = Valor da previsão para o período $t+m$

Para aferir a precisão do modelo a medida de precisão SMAPE (*Symmetric Mean Absolute Percentage Error*) pode ser utilizada, bem como para determinar os melhores valores dos parâmetros (α, β, \emptyset) a considerar (cf. Equação 5).

$$SMAPE = \sum_t \frac{|x_t - \hat{f}_t|}{(x_t + \hat{f}_t)/2} \quad (5)$$

2) Modelo auto-regressivo

Os métodos auto-regressivos são baseados na ideia de que é possível identificar a relação entre as observações e a série temporal, estudando a auto-correlação entre observações separadas por um intervalo fixo de tempo.

Na análise estatística de séries temporais, os modelos *autoregressive-moving-average* (ARMA) fornecem uma pequena descrição de um processo estocástico estacionário em termos de dois polinómios, um para a auto-regressão e outro para a média móvel. O modelo geral ARMA foi descrito em 1951 na tese de Peter Whittle e foi popularizado em 1976 no livro dos autores George Box EP e Gwilym Jenkins [13].

Dada uma série temporal de dados X_t , o modelo ARMA é uma ferramenta para a compreensão e previsão de valores futuros da série. O modelo consiste em duas partes, uma parte auto-regressiva (AR) e uma parte média móvel (MA).

Assim sendo, o modelo é geralmente designado por modelo ARMA (p, q), onde p é a ordem da parte auto-regressiva e q é a ordem da parte média móvel.

Os modelos AR (p) podem ser definidos de uma forma geral pela Equação 6:

$$X_t = \emptyset_1 X_{t-1} + \emptyset_2 X_{t-2} + \dots + \emptyset_p X_{t-p} + a_t \quad (6)$$

onde a_t é um termo de ruído branco (é uma variável aleatória independente e uniformemente distribuída) e p corresponde ao número de termos auto-regressivos. Nos modelos AR (1), o valor de X no período t depende do seu valor no período $t-1$ e um termo de erro aleatório, sendo os valores de X expressos como desvios da sua média; ou seja, o valor previsto para X_t é simplesmente uma proporção (\emptyset_1) do valor de X_{t-1} .

Outro modelo pertencente à família ARMA é o MA (q) que pode ser expresso de acordo com a Equação 7:

$$X_t = \mu + \beta_0 a_t + \beta_1 a_{t-1} + \beta_2 a_{t-2} + \dots + \beta_q a_{t-q} \quad (7)$$

em que μ é uma constante e q é o número de médias móveis existentes.

Nos modelos MA(q) o valor de X no período t é uma constante (μ) a que acresce uma média móvel dos termos de erro presentes (β_0) e passados (β_q). O processo de MA (q) é simplesmente uma combinação linear de termos de erro de um ruído branco (a_t).

Um modelo ainda pode apresentar características de um processo AR (p) e de um processo MA (q). Os Modelos ARMA (p, q) podem ser representados pela Equação 8:

$$X_t = \emptyset + \emptyset_1 X_{t-1} + \beta_0 a_t + \beta_1 a_{t-1} + \emptyset_2 X_{t-2} + \beta_2 a_{t-2} + \dots + \emptyset_p X_{t-p} + \beta_q a_{t-q} \quad (8)$$

onde \emptyset é um termo constante. Os modelos AR (p), MA (q) e ARMA (p, q) pressupõem que a série analisada seja estacionária (média e variância constantes ao longo do tempo).

O ARMA é apropriado quando um sistema é uma função de uma série de eventos não observados (a parte MA), bem como o seu próprio comportamento.

Por exemplo, os valores das cotações das ações financeiras podem ser alterados com base em informações fundamentais sobre o mercado, bem como exibindo tendências e efeitos dos participantes do mercado. Este método pode ser utilizado para fazer a previsão das cotações de ações na Bolsa de Valores, com base no histórico de cotações.

III. PREVISÃO DE VENDAS: O CASO DA EMPRESA DE DISTRIBUIÇÃO FARMACÊUTICA EM PORTUGAL

A. Caracterização do problema

A empresa de distribuição farmacêutica onde foi desenvolvido este estudo está integrada num grupo mundial, tem sede em Portugal e é uma das maiores empresas de comercialização e distribuição farmacêutica ao nível nacional. Através dos vários armazéns da empresa, que suportam a cobertura de todo o território nacional, a empresa garante diariamente às farmácias o acesso aos produtos por ela comercializados, incluindo medicamentos e outros produtos farmacêuticos.

A determinação de encomendas de um produto (medicamento) aos fornecedores da empresa de distribuição farmacêutica é feita com base na análise do histórico das quantidades desse produto pedidas pelos clientes (farmácias) da empresa. Por outro lado, é sabido que existem períodos no ano em que a procura de determinados medicamentos é maior (por exemplo, os antigripais e antipiréticos no Inverno).

Pretende-se, então, identificar padrões regulares de observações históricas nas quantidades encomendadas pelas farmácias de um medicamento, com o objetivo da empresa de distribuição farmacêutica fazer previsões de vendas desses medicamentos para um período futuro. As previsões de vendas por produto, indicarão as quantidades desse produto a encomendar, por parte da empresa de distribuição farmacêutica aos fornecedores.

No conjunto de dados a analisar (quantidades de um produto pedidas pelos clientes/farmácias), o atributo alvo (quantidade do produto a encomendar/mês) é dependente do tempo, ou seja, está associado a uma sequência consecutiva de períodos, e o interesse é conhecer essa dependência.

O problema em causa enquadra-se, assim, num caso de aplicação da categoria de data mining preditivo (pretende-se fazer uma previsão do valor futuro de um atributo de interesse) e do método de data mining de séries temporais descrito na Secção II, uma vez que o atributo alvo (quantidade a encomendar de um medicamento por mês) é dependente do tempo, estando associado a uma sequência consecutiva de períodos e se pretende prever o seu valor para um determinado período futuro (no caso concreto, o mês atual e os dois meses posteriores).

B. Volume de dados envolvidos e pré-processamento

A empresa de distribuição farmacêutica movimentava cerca de 180.000 faturas por mês. A tabela de Faturas inclui dados desde 2005 e tem 5,5GB de tamanho com 13.160.841 registos. A tabela das Linhas de Fatura possui 271.290.537 registos e 38,2 GB de tamanho, sendo adicionados por mês cerca de 3.700.000 novos registos.

Foi criada uma nova tabela para guardar os valores das quantidades de produtos pedidas pelos clientes da empresa, com os dados agregados por produto/mês referentes a cada armazém.

REG_ID_PRODUTO	ANO_MES	ESTAB_ID	QT_PEDIDA
427795	201512	2	40881
427795	201511	2	51538
427795	201510	2	51538
427795	201509	2	55932
427795	201508	2	38908
427795	201507	2	57406
427795	201506	2	54386
427795	201505	2	47933

Figura 1. Exemplo de registos da tabela com dados agregados por produto/mês

Assim, da análise da Figura 1, é possível verificar que o produto com código 427795 teve uma encomenda em dezembro de 2015 de 40881 unidades alocadas ao armazém da empresa com o código “2” e de 51538 unidades alocadas ao mesmo armazém em novembro de 2015.

Os dados desta tabela serviram de base ao processo de previsão de vendas de produtos efetuado e que, do ponto de vista da empresa farmacêutica, corresponderá às quantidades de produto a encomendar.

C. Aplicação do método de previsão de vendas utilizado

O método de Pegels amortecido [12] e a medida de precisão SMAPE descritos na Secção II foram utilizados no cálculo da previsão. O método de Pegels amortecido foi selecionado uma vez que, na comparação com outros métodos de suavização exponencial (Simple, Holt, Damped Holt, Generalised Holt, Pegels, Holt-Winters), é o que apresenta melhores resultados para as 1428 séries mensais da M3-Competition [12]. Por outro lado, a utilização do SMAPE é vantajosa em relação à utilização do MAPE (*Mean Absolute Percentage Error*) mais tradicional,

uma vez que evita grandes erros quando o x_i real está perto de zero, e grandes diferenças entre o erro percentual absoluto quando x_i é maior do que a previsão f_i , e quando f_i é maior do que x_i .

Foi efetuada a previsão de vendas para 357 medicamentos comercializados pela empresa de distribuição farmacêutica. A seleção destes produtos (dos cerca de 20000 produtos comercializados pela empresa) foi feita tendo em conta a relevância das vendas dos mesmos em termos de negócio para a empresa.

A previsão de vendas foi feita para o mês atual à data da realização deste trabalho (janeiro de 2016) e para os dois meses posteriores (fevereiro e março de 2016). A implementação deste método e do cálculo do erro associado foram feitos em SQL, uma vez que a base de dados da empresa (produtos, vendas) é uma base de dados ORACLE versão 11.2.

Cálculo do erro associado e análise e interpretação dos resultados obtidos

Conforme apresentado na Figura 2, os valores gerados α , β , \emptyset referentes ao método de Pegels amortecido e o erro associado SMAPE são guardados na tabela; subsequentemente, é selecionada a combinação das constantes com o menor erro associado para cada produto/armazém ($\alpha=0.1$, $\beta=0.1$, $\emptyset=0.9$).

α	β	\emptyset	SMAPE
PROCESS_CONST	TREND_CONST	DAMPED_CONST	ERROR
0.1	0.9	0.9	1.03948761598306812272568829671448768926
0.1	0.8	0.9	1.07508756556840291322733869219736623547
0.1	0.7	0.9	1.14858142551869769020055303870473012242
0.1	0.6	0.9	1.26308102131417115736927169760497912338
0.2	0.5	0.9	1.27641951381880346794534430477720153512
0.2	0.4	0.9	1.2930678451992910805064550200989458609

Figura 2. Apresentação do erro (SMAPE) ordenado por ordem ascendente e obtido pela combinação das 3 constantes do método

Depois de selecionada a combinação com o menor erro, esta é aplicada para o cálculo da previsão de vendas, sendo o resultado obtido guardado no campo “Quantidade_Prevista” da tabela (cf. Figura 3).

ANO_MES	ESTAB_ID	REG_ID_PRODUTO	QUANTIDADE_VENDIDA	QUANTIDADE_PREVISTA
201603	2	427795		49081
201602	2	427795		50074
201601	2	427795	51153	51191
201512	2	427795	40881	53372
201511	2	427795	51538	53502
201510	2	427795	51538	53443
201509	2	427795	55932	52668
201508	2	427795	38908	53975
201507	2	427795	57406	51841
201506	2	427795	54386	50230

Figura 3. Exemplo da aplicação do método de previsão de vendas

Para uma visualização dos resultados da aplicação do método de previsão de vendas mais “user-friendly”, foi desenvolvida uma aplicação visual em ORACLE APEX versão 4.2 (cf. Figura 4).




Figura 4. Ecrã do CRM da empresa, com a representação gráfica das quantidades pedidas pelos clientes (a cor azul – Qtd. Pedida) de um produto selecionado e correspondente previsão de vendas (a cor vermelha – Qtd. Prevista)

Assim, para o produto selecionado (ASPIRINA GR 100 MG COMP GR X30) e para o armazém de venda “Maia”, tendo em conta a análise do histórico das quantidades desse medicamento pedidas pelos clientes entre janeiro de 2014 e dezembro de 2015 (24 meses), as quantidades previstas de venda do medicamento para o mês atual (janeiro de 2016) e para fevereiro e março de 2016 serão de 51 191, 50074 e 49081 unidades respetivamente.

À data da realização deste trabalho, o processo utilizado pela empresa de distribuição farmacêutica para determinar a quantidade a encomendar de um dado produto para o mês seguinte era baseado no cálculo da média aritmética das quantidades vendidas desse produto nos últimos 12 meses (cf. Figura 5).

Para o caso do produto já referido (ASPIRINA GR 100 MG COMP GR X30) e para o mesmo armazém de venda, a tabela da Figura 5 apresenta os valores das quantidades previstas de vendas determinadas através do método de Pegels amortecido e com o processo de cálculo da média de vendas utilizado pela empresa.

ANO MES	ESTAB ID	REG ID PRODUTO	QUANTIDADE VENDIDA	QUANTIDADE PREVISTA PEGELS	QUANTIDADE PREVISTA (processo utilizado empresa)
201603	2	427795			49.081
201602	2	427795			50.074
201601	2	427795	51.153		51.191
201512	2	427795	40.881		53.372
201511	2	427795	51.538		47.398
201510	2	427795	51.538		53.443
201509	2	427795	55.932		52.668
201508	2	427795	38.908		53.975
201507	2	427795	57.406		51.841
201506	2	427795	54.386		50.230
201505	2	427795	47.933		49.461
201504	2	427795	50.219		48.108
201503	2	427795	47.438		47.018
201502	2	427795	46.029		45.907
201501	2	427795	46.739		44.503

Figura 5. Exemplo de registos da tabela com dados agregados por produto/mês

Da análise da tabela, constata-se que os valores obtidos pelo método de Pegels estão na generalidade mais próximos dos valores reais do que os obtidos com o processo atualmente em vigor na empresa. Para além disso, é importante referir que os valores obtidos pelo método de Pegels satisfazem na maioria dos

casos a procura, o que não acontece no cálculo feito pelo outro processo.

IV. CONCLUSÃO E TRABALHO FUTURO

Do estudo e aplicação efetuados na empresa de distribuição farmacêutica retratada neste trabalho, é possível concluir que o desempenho do método de séries temporais Pegels amortecido foi favorável na previsão de vendas de produtos ao nível individual, obtendo-se resultados mais aproximados aos reais e mais confiáveis, em comparação com o processo anteriormente utilizado pela empresa. Verificou-se que, utilizando os valores obtidos pelo método de Pegels amortecido para a previsão de vendas, a empresa poderia melhor determinar os valores a encomendar dos produtos em causa, garantido na maioria dos casos níveis de *stock* que efetivamente pudessem satisfazer os valores de procura real, sem considerar níveis de stocks excessivos e com forte impacto nos custos.

Quanto ao método de previsão de vendas utilizado e apesar dos resultados obtidos terem sido satisfatórios, considera-se que ainda há espaço para introduzir melhorias na técnica de previsão. Por um lado, seria interessante verificar se, com a utilização de um horizonte de previsão mais amplo do que o que foi utilizado neste trabalho, os resultados obtidos poderiam ter uma precisão que pudesse ser considerada aceitável. A inclusão de um horizonte de previsão mais alargado (por exemplo, 12 meses) na previsão de vendas, poderá ter interesse para a empresa de distribuição farmacêutica conseguir uma maior margem de manobra na negociação de preços com os fornecedores.

Por outro lado, aspetos como dados da realização de ações publicitárias por parte dos fornecedores e dados de promoções efetuadas pela concorrência (outras empresas de distribuição farmacêutica) poderão ter impacto nas vendas reais dos produtos. Assim, poderia ser equacionada a possibilidade de estes aspetos serem considerados como variáveis adicionais na determinação da previsão de vendas.

Por último, a comparação do desempenho do método de Pegels amortecido com outros métodos de previsão de séries temporais poderia constituir objeto de estudo.

REFERÊNCIAS BIBLIOGRÁFICAS

- [1] A. Gupta, C. D. Maranas, and C. M. McDonald, “Mid-term supply chain planning under demand uncertainty: customer demand satisfaction and inventory management,” *Comput. Chem. Eng.*, vol. 24, pp. 2613–2621, 2000.
- [2] P. Doganis, A. Alexandridis, P. Patrinos, and H. Sarimveis, “Time series sales forecasting for short shelf-life food products based on artificial neural networks and evolutionary computing,” *J. Food Eng.*, vol. 75, pp. 196–204, 2006.
- [3] N. K. Zadeh, M. M. Sepehri, and H. Farvareh, “Intelligent Sales Prediction for Pharmaceutical Distribution Companies : A Data Mining Based Approach,” vol. 2014, 2014.
- [4] M. Santos and I. Ramos, *Business Intelligence: Tecnologias da Informação na Gestão de Conhecimento*. FCA, 2009.
- [5] Vercellis C, *Business intelligence data mining and organization for decision making*, 2nd ed. Chichester: John Wiley & Sons, 2009.
- [6] J. Han, M. Kamber, and J. Pei, *Data Mining: Concepts and Techniques*. Elsevier, 2011.
- [7] M. J. A. Berry and G. S. Linoff, *Mastering Data Mining: The Art and Science of Customer Relationship Management*. Wiley, 2000.
- [8] P. R. Winters, “Forecasting Sales by Exponentially Weighted Moving Averages,” *Manage. Sci.*, vol. 6, pp. 324–342, 1960.

- [9] S. Makridakis, S. Wheelwright, C., and R. J. Hyndman, *Forecasting: methods and applications*. John Wiley & Sons, cop., 1998.
- [10] J. Gardner, E.S. and E. McKenzie, "Forecasting trends in time series," *Manage. Sci.*, vol. 31, pp. 1237–1246, 1985.
- [11] C. C. Pegels, "Exponential forecasting: Some new variations," *Manage. Sci.*, vol. 15, pp. 311–315, 1969.
- [12] J. W. Taylor, "Exponential Smoothing with a Damped Multiplicative Trend Exponential Smoothing with a Damped Multiplicative Trend," *Int. J. Forecast.*, vol. 19, no. 0, pp. 715–725, 2003.
- [13] G. E. P. Box and G. M. Jenkins, *Time Series Analysis: Forecasting and Control*, 2nd ed. San Francisco: Holden-Day, 1976.