

# **Metodologia para análise de impactos de campanhas de um retalhista especializado**

*Paulo Fernando Rocha Santos Pinho*

**Dissertação de Mestrado**

Orientador na FEUP: Prof. Pedro Amorim



**Mestrado Integrado em Engenharia Industrial e Gestão**

2016-07-04

## Resumo

Esta dissertação propõe uma metodologia para a determinação, análise e estimação de impactos de campanhas de um retalhista especializado. A intensa frequência e diversidade promocional, a quantidade de artigos e a sua sazonalidade caracterizam o retalhista. Dada a sua complexidade, apenas as principais campanhas são analisadas, efetuando a comparação com as homólogas do ano anterior ou estabelecendo um período comparável. Desenvolveu-se uma metodologia uniforme para a determinação de impactos da generalidade das campanhas. Utilizaram-se os dados históricos para a estimação de impactos futuros, auxiliando o processo de construção de novas campanhas.

O impacto foi definido como o aumento de vendas devido à realização da promoção, apenas para os artigos e período em campanha. Comparam-se as vendas reais com um *baseline*, dado por um modelo de previsão de vendas, que retrata um cenário teórico sem campanha. Este modelo tem por base as três semanas anteriores ao início de cada campanha. Foi conduzida uma análise estatística aos impactos obtidos, de modo a destacar fatores com efeitos relevantes no impacto promocional. Posteriormente, estimaram-se os impactos esperados, tendo em conta os fatores analisados.

O tipo de marca e o desconto percentual emitido mostraram-se estatisticamente significativos. Para descontos superiores, poderá existir uma maior diferença entre os impactos da marca de fornecedor e marca própria. O comportamento dos géneros homem e mulher depende da tipologia de artigos. A gama júnior apresentou consistentemente menores impactos que a gama de adulto. O valor absoluto do desconto poderá ter efeitos significativos no impacto promocional.

Para o desenvolvimento de modelos de previsão de impactos foram utilizadas as técnicas de regressão múltipla e árvores de regressão. Os seus resultados não se apresentaram satisfatórios para as necessidades do problema. Em alternativa, os impactos são estimados a partir de intervalos de confiança, baseados nas análises de variância realizadas. A incerteza associada ao cálculo do *baseline* poderá explicar o fraco desempenho de algumas das técnicas empregues.

# **Methodology for the analysis of the promotional impact in a specialized retailer**

## **Abstract**

This dissertation proposes a methodology for the determination, analysis and estimation of the promotional impacts of a specialized retailer. This retailer is characterized by its intense and diversified promotional activity, along with a high range of seasonal products. Due to its complexity, only the major events are analyzed and compared to their homologous, in the previous year. A standardized procedure for the calculation of the promotional impact was developed. Using historic data, future impacts are estimated in order to support the decision process in the design of new campaigns.

Promotional impact was defined as the increase in sales caused by the promotion, for the campaign products and its duration only. The actual sales are compared to a baseline, given by a sales forecasting model. The baseline represents a theoretical scenario without promotional activity and is determined by a three-week period previous to the campaign. A statistical analysis on the computed impacts was conducted. The effect of a set of variables on the impact is studied. Afterward, the expected impacts were estimated, taking the significant variables into account.

The brand type and the relative price discount were shown to be statistically significant. For higher discounts, the difference between the impacts of the provider and own brands may be higher. The behavior from man and women products depends from its typology. The junior product range reflected consistently smaller impacts than the adult range. The absolute price discount can have relevant effects on the impact.

For the prediction of future impacts, multiple regression and regression trees were used. The achieved results did not attain the project needs. Alternatively, the impacts were estimated through confidence intervals, based on the performed analysis of variance. The low performance of some of the used techniques may result from the uncertainty from the computation of the baseline.

## Agradecimentos

Devo um agradecimento a todos os que contribuíram para esta dissertação.

A toda a equipa de *Business Intelligence* da Sport Zone, pelo seu acolhimento imediato, pela ajuda com a máxima prontidão e por todo o conhecimento transmitido. Agradeço especialmente ao Bruno Pereira, que acompanhou e guiou todo o processo, lidando com os problemas da forma mais expedita possível. À Sonae, pela oportunidade e experiência que me foram concedidas.

Ao Professor Pedro Amorim, pelos sempre valiosos contributos, pela constante defesa e pelo sentido de orientação. Ao Professor Sarsfield Cabral, pela partilha do seu vasto conhecimento de estatística.

Aos meus amigos, pela companhia, desabafos e especialmente muitos sorrisos.

Por fim, à minha família, que sempre aturou as minhas frustrações e me permitiu chegar até aqui. Ao meu irmão em particular, pela bibliografia que me forneceu, revelando-se numa preciosa ajuda.

# Índice de Conteúdos

1	Introdução .....	1
1.1	Projeto.....	1
1.2	Objetivos.....	2
1.3	Estrutura da dissertação .....	2
2	Estado da arte.....	3
2.1	Métodos de previsão .....	3
2.2	Previsão de vendas na presença de promoções .....	5
2.3	Estatística descritiva e Inferência .....	6
2.4	Decomposição de efeitos promocionais.....	7
2.5	Análise crítica .....	9
3	Definição do problema.....	10
3.1	Estrutura organizacional .....	10
3.2	Parametrização de campanhas .....	11
4	Metodologia para análise de campanhas .....	13
4.1	Apuramento de impactos históricos.....	14
4.1.1	Dados.....	14
4.1.2	Impacto.....	15
4.1.3	Baseline .....	16
4.2	Previsão de impactos futuros .....	19
4.2.1	Análise.....	19
4.2.2	Previsão .....	20
4.3	Acompanhamento de campanhas.....	21
4.4	Aplicação prática .....	21
4.4.1	Base de dados .....	21
4.4.2	Simulador de impactos .....	21
4.4.3	Ferramenta de acompanhamento .....	22
5	Resultados e discussão .....	23
5.1	Análise estatística .....	23
5.1.1	Desconto percentual e tipo de marca .....	23
5.1.2	Tipologia e género.....	27
5.2	Regressão linear múltipla e árvore de regressão .....	28
5.3	Intervalos de confiança .....	29
5.4	Erro na determinação do <i>baseline</i> .....	30
6	Conclusões e perspetivas de trabalho futuro.....	32
6.1	Principais resultados .....	33
6.2	Limitações e perspetivas de trabalho futuro .....	34
	Referências .....	35
	ANEXO A: Categorias da unidade de negócio de Fitness e Essentials.....	38
	ANEXO B: Recolha e filtragem da Base de Dados .....	39
	ANEXO C: Análise e previsão de impactos.....	41
	ANEXO D: Ferramenta simuladora de impactos .....	43
	ANEXO E: Ferramenta de acompanhamento de campanhas.....	46
	ANEXO F: Resultados da análise estatística .....	47
	ANEXO G: Resultados da previsão de impactos .....	53

## Siglas

ADL – *Autoregressive Distributed Lag*

AIC – *Akaike Information Criterion*

ANOVA – *Analysis of Variance*

ARIMA – *Autoregressive Integrated Moving Average*

ARMA – *Autoregressive Moving Average*

DSS – *Decision Support System*

FSS – *Forecasting Support System*

MAD – *Mean Absolute Deviation*

MSE – *Mean Squared Error*

SVR – *Support Vector Regression*

SQL – *Structured Query Language*

## Índice de Figuras

Figura 1 - Hierarquia principal da estrutura mercadológica da Sport Zone .....	11
Figura 2 - Unidades de negócio da Sport Zone .....	11
Figura 3 - Quadro global do projeto realizado .....	13
Figura 4 - Janela temporal utilizada para o <i>baseline</i> .....	16
Figura 5 - Correção de <i>outliers</i> no cálculo do <i>baseline</i> .....	17
Figura 6 - Diagrama da abordagem utilizada para o cálculo do <i>baseline</i> .....	17
Figura 7 - Metodologia para o cálculo da média móvel semanal.....	18
Figura 8 - Efeito da unidade de negócio no impacto promocional.....	24
Figura 9 - Efeitos do tipo de marca e desconto na unidade de negócio de Fitness e Essentials .....	24
Figura 10 - Efeitos do tipo de marca e desconto na unidade de negócio de Casual.....	25
Figura 11 - Efeito do fator desconto na unidade de negócio de ciclismo.....	25
Figura 12 - Efeito da categoria no impacto promocional .....	26
Figura 13 - Efeitos do tipo de marca e desconto na categoria de Essentials Têxtil Júnior.....	26
Figura 14 - Efeito da tipologia no impacto promocional .....	27
Figura 15 - Efeitos do género e tipo de marca em têxtil na unidade de negócio de Fitness e Essentials .....	28
Figura 16 - Exemplo retirado da tabela de impactos desenvolvida.....	30
Figura 17 - Histograma e <i>boxplot</i> das amplitudes dos intervalos de confiança obtidos.....	30

## Índice de Tabelas

Tabela 1 - Exemplos de resultados obtidos com regressão múltipla e árvore de regressão .....29

## 1 Introdução

As campanhas realizadas no setor do retalho representam uma porção significativa das vendas totais dos retalhistas (Gedenk et al. 2010). Assim, a análise à rentabilidade das ações promocionais torna-se um processo crítico para estas organizações. Os retalhistas necessitam de perceber quais os tipos de campanhas, assim como as características que as compõem, que maximizam o seu desempenho. Nesta dissertação, é apresentada uma metodologia para a análise e previsão do impacto promocional de um retalhista especializado.

O projeto foi realizado na Sport Zone, um retalhista na área do equipamento e vestuário desportivo. A Sport Zone é uma das insígnias que compõem a Sonae SR, responsável pela área não alimentar, especializada, do grupo Sonae. O grupo Sonae considera o retalho como o seu negócio *core*, dividindo-o pela área alimentar (Sonae MC) e não alimentar (Sonae SR). Para além do retalho, opera em outras áreas como as telecomunicações, centros comerciais e tecnologia.

A Sport Zone é, atualmente, a maior cadeia de lojas de desporto em Portugal (79 lojas) e tem uma presença importante em Espanha (32 lojas). A empresa também está presente fora da península Ibérica, num formato de franquia. A sua oferta apresenta uma grande variedade de desportos, compreendendo dezenas de milhares de artigos. A sua gama é caracterizada por uma alta sazonalidade, derivada da sua divisão em coleções. A empresa pratica, anualmente, inúmeras ações promocionais, de diferentes dimensões e características. O âmbito das campanhas realizadas estende-se a todas as suas lojas e artigos, atingindo todos os níveis da sua estrutura mercadológica.

### 1.1 Projeto

Previamente à realização deste projeto, a análise de campanhas cingia-se às grandes campanhas, como os meses temáticos, por exemplo. O seu estudo baseava-se na comparação de vendas e margens entre a grande campanha e a sua homóloga do ano anterior. Para além de que a maior parte das campanhas realizadas não eram analisadas detalhadamente, a abordagem apresenta várias falhas. A comparação com um período anterior não determina o verdadeiro impacto da ação promocional no negócio, mas sim a diferença de desempenho face à última ocorrência. A falta de comparabilidade entre os dois períodos põe em causa a análise. Para calendários promocionais com diferentes horizontes temporais, é necessário algum tipo de extrapolação para o seu comportamento. De modo adicional, a alta sazonalidade dos seus artigos faz com que, no espaço de um ano, a composição da estrutura mercadológica varie consideravelmente, dado que pertencem a coleções diferentes.

Dado que a avaliação do desempenho promocional era realizada para um conjunto muito restrito de campanhas, não existia uma base com informação suficiente sobre os impactos de campanhas históricas e, pela mesma razão, subsistia a falta de noção sobre quais os fatores que poderão influenciar o seu impacto.

As campanhas são um assunto transversal à empresa, afetando, inevitavelmente, todos os seus departamentos. O projeto foi desenvolvido dentro do *Business Intelligence*, uma equipa

transversal que tem como principais funções o apoio ao processamento e análise de todo o tipo de informação relativa ao negócio. Consoante o tipo de campanha, o desenho das ações promocionais é efetuado por diferentes departamentos.

Desenvolveu-se uma nova metodologia para a análise do impacto de campanhas da empresa. Uma abordagem uniforme, que permite determinar o impacto da generalidade das campanhas históricas, possibilita a análise de fatores importantes para o seu desempenho, assim como a estimação dos seus impactos. Desta forma, o processo de decisão sobre a conceção de campanhas futuras que, até à data, não contava com dados suficientes para serem efetuadas decisões informadas, passa a ser mais suportado.

## 1.2 Objetivos

O projeto é dividido em três objetivos principais. O primeiro objetivo corresponde ao apuramento dos impactos de campanhas históricas. A sua execução compreende duas fases: a extração de dados de campanhas históricas e o cálculo do seu impacto. A extração materializa-se numa base de dados, com um nível de agregação e âmbito bem definidos. Posteriormente, é determinado o impacto de cada campanha. Define-se como impacto o aumento de vendas com origem na campanha, face a um cenário teórico sem campanha. As vendas do cenário sem campanha são denominadas de *baseline*. O *baseline* é determinado a partir de um modelo de previsão de vendas, desenvolvido para o efeito.

Utilizando os impactos de campanhas históricas obtidos, o segundo objetivo tem por base a análise estatística desses impactos e a sua previsão para o futuro. A análise estatística tem a finalidade de identificar os efeitos de alguns fatores que poderão influenciar o desempenho de uma campanha. Com base nesta análise é possível desenvolver modelos de previsão com vista a estimar impactos futuros. A concretização do objetivo é ultimada pela elaboração de uma ferramenta simuladora de impactos que, utilizando a análise e previsões obtidas anteriormente, permite estimar os impactos de uma campanha futura consoante um conjunto de fatores que a caracteriza.

O terceiro e último objetivo é o desenvolvimento de uma ferramenta de acompanhamento de campanhas a decorrer, recorrendo, se possível, à mesma abordagem utilizada no cálculo dos impactos históricos.

## 1.3 Estrutura da dissertação

O corpo da dissertação está dividido em quatro capítulos. Primeiramente, no capítulo 2, é apresentado o estado da arte relativo à análise promocional. Neste âmbito, a literatura é repartida no desenvolvimento de modelos de previsão de vendas em períodos promocionais e na decomposição do impacto em diversos efeitos. Ainda no estado da arte, são expostos os principais modelos de previsão, assim como uma breve referência à estatística descritiva e inferência.

No capítulo 3 é definido o problema abordado no projeto e o seu enquadramento. A estrutura organizacional da empresa e o processo de parametrização de campanhas são referidos com maior detalhe.

O capítulo 4 corresponde à exposição da metodologia desenvolvida. Dividiu-se o capítulo pelos três objetivos do projeto, acrescentando, no final, a sua aplicação prática. A sua estrutura compreende a abordagem utilizada para o apuramento dos impactos históricos, a análise e previsão de impactos futuros e o acompanhamento de campanhas.

Os resultados obtidos com a aplicação da metodologia figuram no capítulo 5, juntamente com uma posterior discussão sobre os mesmos. Por fim, apresentam-se as conclusões do projeto e sugestões para trabalhos futuros no capítulo 6.

## 2 Estado da arte

O presente capítulo introduz o estado da arte da literatura sobre análise promocional e, adicionalmente, uma contextualização sobre a generalidade dos métodos de previsão e análise estatística. O estado da arte da análise promocional está dividido em duas secções. A primeira incide sobre o desenvolvimento de modelos de previsão de vendas na presença de campanhas, enquanto a segunda apresenta os principais resultados da análise aos efeitos resultantes das promoções. Mondom (2013) apresenta uma visão geral dos tópicos estudados no âmbito da literatura promocional.

### 2.1 Métodos de previsão

A previsão é uma parte fundamental no processo de decisão das diferentes atividades de uma organização. Os métodos de previsão baseiam-se em dados históricos e/ou conhecimentos adquiridos para antecipar o comportamento futuro de certas variáveis.

Pode-se dividir o leque de métodos de previsão em dois grandes grupos: métodos quantitativos e qualitativos. Um dos fatores relacionados com a escolha do método a usar é a disponibilidade de informação necessária para a previsão. Se existir informação suficiente sobre o passado e a mesma possa ser transformada em dados numéricos, poderão ser aplicados métodos quantitativos. Não existindo informação histórica suficiente, terão de ser utilizados métodos qualitativos (Makridakis et al. 1998).

Dentro dos métodos quantitativos, as principais técnicas utilizadas podem ser repartidas em técnicas de extrapolação direta, baseadas em séries temporais, e causais. As primeiras tentam decompor as séries temporais em diferentes componentes, como a tendência e a sazonalidade, enquanto as técnicas causais são utilizadas para descobrir relações de dependência entre variáveis explicativas e a variável a prever.

As técnicas de extrapolação direta compreendem diferentes famílias de métodos.

O método de decomposição clássica é a base da maior parte das abordagens mais recentes (Makridakis et al. 1998). Consiste na decomposição das séries temporais em duas componentes: tendência e sazonalidade. A tendência é determinada a partir do cálculo de uma média móvel e a sazonalidade é dada por índices de sazonalidade para cada período, calculados depois de retirados os efeitos da tendência.

A família de técnicas de amortecimento exponencial representa uma importante fatia nos métodos de extrapolação. O principal conceito subjacente a estas técnicas é o uso de pesos às diferentes observações, dando maior ênfase às mais recentes. Assim, as observações mais antigas terão um peso exponencialmente menor na previsão, permitindo uma maior reatividade ao modelo. Gardner (2006) apresenta uma revisão do estado da arte das várias abordagens usadas.

Ainda no campo dos modelos baseados em séries temporais, destacam-se também os modelos autorregressivos que, à semelhança de uma regressão, estabelecem relações de dependência entre variáveis explicativas e a variável de previsão. Neste caso, as variáveis explicativas são

as observações anteriores da própria variável a prever. Box e Jenkins (1970) desenvolveram uma metodologia para os modelos ARIMA, em que se combinam técnicas autorregressivas com médias móveis. Esta metodologia pode ser aplicada em séries não estacionárias, o que não era possível com os modelos anteriores, como o ARMA.

Os modelos de extrapolação apresentam uma relação de simplicidade e aplicabilidade com bons resultados. Contudo, estes modelos não tentam perceber porque é que as variações acontecem, nem incorporam fatores externos que poderão ser relevantes, como as promoções (Trapero et al. 2013).

Desta necessidade advêm os modelos causais que, através de uma função, criam correlações entre fatores e o resultado final. Estes modelos, dentro dos já enumerados, são os modelos mais sofisticados, dado que não só incorporam efeitos externos como também podem incluir séries temporais. Existe também uma acrescida complexidade associada a estes modelos, na medida em que é necessário predeterminar as relações entre as variáveis (Chambers et al. 1971).

A regressão simples estabelece uma relação entre apenas uma variável independente e uma variável dependente. Este modelo é um caso especial da regressão múltipla, que incorpora um conjunto de duas ou mais variáveis explicativas (ou independentes). Existem ainda modelos mais complexos dos quais a regressão múltipla é também um caso especial. É o caso dos modelos econométricos, em que existem mais do que uma variável de previsão e vários fatores explicativos. Para isso, é necessário desenvolver um sistema de equações, em que os parâmetros são estimados conjuntamente (Makridakis et al. 1998).

Para além da extrapolação direta e dos modelos causais, no âmbito dos métodos de previsão existem técnicas alternativas, como os métodos de inteligência artificial.

As redes neuronais artificiais, modelos matemáticos baseados no sistema nervoso do cérebro, são um exemplo destes métodos (Fildes et al. 2008). Contrariamente aos modelos causais, em que é necessário determinar *a priori* as relações entre as variáveis de entrada e a variável de previsão, o principal objetivo desta técnica é a deteção de relações não lineares mais complexas. Uma rede neuronal é representada por um conjunto de neurónios e ligações representadas por pesos. Pode-se afirmar que atuam como uma caixa preta, já que não é possível traduzir os pesos em relações explícitas entre as variáveis de entrada e saída.

Hill et al. (1994) conclui que o desempenho das redes neuronais é comparável com outras técnicas estatísticas. O facto de requererem um maior número de observações e atuarem como uma caixa preta são as principais desvantagens do método.

A aprendizagem através de árvores de decisão é também uma técnica já estabelecida dentro dos métodos de *data mining* e *machine learning* (Fildes et al. 2008). Os modelos em que a variável de previsão contém apenas um conjunto possível finito de valores são denominados de árvores de classificação, ao passo que as árvores de regressão são utilizadas quando a variável de previsão é contínua. Estas técnicas são particularmente úteis quando não se conseguem identificar as relações entre as diferentes variáveis. Adicionalmente, o seu resultado é facilmente interpretável dada a sua estrutura visual (Buntine 1992).

As técnicas de inteligência artificial, juntamente com a extrapolação direta e modelos causais, completam a maior parte do leque dos métodos quantitativos.

Os métodos quantitativos estabelecem relações ou padrões, assumindo que o seu comportamento se manterá constante no futuro. Contudo, na prática, é necessária a deteção de mudanças que possam ocorrer, de maneira a evitar grandes erros de previsão. Nestes casos, apenas é possível fazê-lo com intervenção humana (Makridakis et al. 1998). Lawrence et al. (2006) consideram que o uso de ajustamentos é uma componente indispensável na previsão e que pode apresentar melhorias significativas na redução dos erros de previsão. Não obstante,

o grande desafio dos ajustamentos de cariz humano passa pela introdução de *bias*. Ao contrário do erro aleatório que advém da variação não explicada dos modelos, o *bias* criado pelos ajustamentos é um erro sistemático, neste caso provocado pelas limitações humanas no processo de decisão (Tversky e Kahneman 1974).

Os ajustamentos podem ser considerados como uma combinação de métodos de previsão. A combinação de diferentes métodos pode melhorar substancialmente o desempenho da previsão. Clemen (1989) conclui que esta afirmação é verdadeira tanto para métodos estatísticos como para qualitativos. O estudo realizado indica que combinações mais simples resultam maioritariamente em melhores performances, comparando com combinações mais complexas.

Nas empresas, a maior parte das decisões operacionais são baseadas numa previsão de vendas. Para empresas que lidam com um número elevado de artigos, a simplicidade dos métodos de amortecimento exponencial permite construir inúmeras previsões, de um modo automático. Apesar da simplicidade, Makridakis e Hibon (2000) demonstram que modelos de previsão mais simples podem atingir melhores resultados do que técnicas mais sofisticadas. Contudo, modelos mais complexos podem ser utilizados. Por exemplo, Sousa (2011) aplica redes neuronais para a previsão de vendas de um retalhista.

A decisão sobre o nível de agregação que maximiza o desempenho da previsão de vendas é um dos seus principais desafios. A determinação do nível de agregação das vendas é normalmente efetuada considerando a conjugação de três fatores: tempo, artigos e lojas. O período temporal no qual são agregadas as vendas (diário ou semanal, por exemplo) e o horizonte temporal da previsão são as duas principais variáveis da agregação temporal. A previsão de vendas para um artigo ou para uma loja, por exemplo, é significativamente mais difícil do que para um conjunto agrupado (Zotteri et al. 2005).

## 2.2 Previsão de vendas na presença de promoções

Segundo Ali et al. (2009), os modelos de previsão de vendas baseados em séries temporais simples apresentam resultados mais precisos do que técnicas mais complexas para períodos sem promoções. Contudo, para as janelas temporais com promoções, modelos que incorporam fatores adicionais apresentam melhores resultados.

As vendas promocionais representam uma porção significativa das vendas totais dos retalhistas (Gedenk et al. 2010). Desta forma, surge uma necessidade, por parte dos retalhistas, de desenvolver modelos de previsão de vendas que incorporem efeitos promocionais.

Existem na literatura maioritariamente dois tipos de abordagens a este problema.

A primeira consiste no desenvolvimento de modelos de previsões de vendas sem efeitos promocionais, aplicando posteriormente um ajustamento. Este ajustamento pode ser definido manualmente por especialistas ou automaticamente através da aplicação de uma função à previsão inicial. Esta função prevê o aumento de vendas da campanha e é apenas ativada nos períodos promocionais.

A segunda abordagem tem por objeto a produção de modelos que incluem diretamente os efeitos promocionais. Para este efeito, utilizam-se usualmente técnicas de regressão múltipla ou de inteligência artificial (Ma et al. 2015).

Trapero et al. (2013) e Trapero et al. (2015) desenvolvem um modelo de ajustamento automático, aplicando uma função de transferência que é ativada nos períodos promocionais, comparando a metodologia com um sistema de previsão de vendas ajustado manualmente pelos gestores de categorias e marcas. A função de transferência é construída a partir de um método econométrico que, considerando o aumento de vendas de promoções anteriores, prevê

o impacto futuro. As principais vantagens associadas à primeira metodologia, segundo Trapero et al. (2013), consistem na redução do esforço humano exigido para os ajustamentos e um menor erro pode ser atingido. Contudo, apesar de, no geral, o modelo de ajustamento automático ter apresentado menores erros de previsão, em alguns casos o conhecimento humano suplanta os resultados do primeiro.

Ali et al. (2009) comparam modelos de diferentes complexidades tanto a nível de técnicas utilizadas como na introdução das variáveis explicativas. As diferentes técnicas estudadas variam desde o amortecimento exponencial simples com um ajustamento igual ao incremento da promoção anterior mais recente até às árvores de regressão. Os resultados evidenciam que a introdução de variáveis explicativas de maior complexidade só é favorável quando são usadas técnicas mais avançadas que possam incorporar essa sofisticação.

É de salientar que os modelos utilizados por Ali et al. (2009) incorporam não só o desconto percentual associado à promoção como também o preço original e a baixa de preço absoluta. Além de variáveis relacionadas com as próprias promoções, Huang et al. (2014) incluem fatores externos relativos à concorrência, como os preços e as promoções de produtos concorrentes. Os autores utilizam um modelo *Autoregressive Distributed Lag* (ADL), que não só incorpora as vendas de períodos anteriores, como também permite adicionar variáveis promocionais exógenas em forma de regressão.

A previsão de vendas ao nível do artigo necessita de um tipo especial de sistema de apoio à decisão (DSS), denominado de sistema de apoio à previsão (FSS) (Fildes et al. 2006).

Cooper et al. (1999) descrevem a implementação de um sistema de apoio à previsão, *PromoCast*, que abrange todos os artigos de uma cadeia de supermercados, utilizando para isso um modelo de regressão com 67 variáveis explicativas, contendo informação sobre vendas e promoções históricas, características das diferentes lojas, assim como o desconto e outros parâmetros que caracterizam as promoções.

Posteriormente, foi desenvolvida uma metodologia que consiga identificar quais os fatores relevantes para incorporar no modelo de previsão, já que muitas das variáveis que descrevem os produtos, lojas e promoções são categóricas, necessitando por vezes de milhares de níveis por cada atributo (Trusov et al. 2006). A partir do sistema *PromoCast*, a abordagem aplica técnicas de *data mining* e otimização combinatória para a criação de um sistema híbrido.

Entretanto, outros sistemas utilizando modelos de regressão sofisticados foram desenvolvidos, como o *CHAN4CAST* (Divakar et al. 2005) e *SCAN\*PRO* (van Heerde et al. 2002).

Os métodos de inteligência artificial apresentam-se como uma alternativa às técnicas de regressão múltipla, na previsão de vendas promocionais. Ali et al. (2009) utilizam técnicas de inteligência artificial como as árvores de regressão e *Support Vector Regression* (SVR), método que consiste na divisão de um espaço através de um hiperplano, com o objetivo de separar os pontos da variável dependente de acordo com as variáveis independentes.

Poh et al. (1998) utilizam redes neuronais para a previsão do impacto promocional, empregando informação relacionada com a publicidade e os diferentes canais de comunicação. Conduzindo uma análise de sensibilidade, os autores concluem que é possível detetar quais as variáveis independentes mais significativas.

### 2.3 Estatística descritiva e Inferência

Em contraste com o âmbito preditivo dos métodos referidos anteriormente, a estatística descritiva e inferência têm como objetivo a análise e interpretação de dados. O propósito da estatística descritiva é a extração de informação presente num conjunto de dados, representando-a de uma forma mais compreensível, através de certas medidas, gráficos ou

tabelas. A inferência estatística, por outro lado, pretende caracterizar uma população, servindo-se apenas de amostras da mesma (Guimarães e Cabral 2011).

A estimação por intermédio de intervalos de confiança é um exemplo de um método de inferência estatística. Esta abordagem foca-se em estimar um parâmetro de uma população, fornecendo uma medida de confiança para as estimativas obtidas. A confiança requerida é determinada à partida e delimita o âmbito possível do erro de estimação. Outro exemplo de inferência estatística é o teste de hipóteses. Esta técnica permite aferir se as amostras seguem ou não hipóteses definidas *a priori* sobre determinadas populações.

O teste de hipóteses compara os parâmetros de, no máximo, duas populações diferentes. Com a análise de variância, também conhecida como ANOVA, é possível comparar parâmetros de mais do que duas populações. Esta técnica permite não só reconhecer os fatores que causam variação na variável dependente como também aferir qual a sua contribuição. A interação entre os diferentes fatores também é estudada.

A principal diferença entre a análise de variância e a regressão é o facto de que o modelo utiliza variáveis independentes categóricas, em contraste com a regressão, que utiliza várias independentes contínuas, para prever uma variável dependente contínua. Os modelos de regressão múltipla podem também incluir variáveis categóricas, através de variáveis mudas.

Para o modelo poder ser aplicado, é necessária a satisfação de condições impostas aos erros resultantes do mesmo. Os resíduos devem seguir uma distribuição normal, com valor esperado nulo e variância constante (homoscedasticidade) e, por último, ser mutuamente independentes. Keselman et al. (1998) efetuam uma análise à verificação, pela comunidade científica, das condições exigidas sobre os erros.

Na prática, os requisitos impostos aos erros podem ser contornados. Welch (1951) desenvolve um método alternativo para conduzir análises de variância, considerando a variância não constante (heteroscedasticidade). Se a dimensão das amostras não for pequena, a normalidade da distribuição não é crítica para a análise, já que a teoria do limite central garante que as distribuições admitidas para as estatísticas de teste utilizadas sejam razoáveis aproximações à realidade (Guimarães e Cabral 2011).

A ANOVA é mais potente quando são planeadas experiências próprias para o efeito. Todavia, pode ser aplicada para amostras não planeadas (Guimarães e Cabral 2011). No segundo caso, experiências não planeadas levarão a amostras de diferentes dimensões. Para análises de variância com mais de um fator, a estimação dos parâmetros do modelo para este caso pode ser feita através do tipo III dos mínimos quadrados (Herr 1986). Este tipo é independente da dimensão das amostras utilizadas para a análise de variância e tem em conta tanto os efeitos dos fatores como as suas interações. O tipo II é utilizado quando as interações entre os fatores não são significativas. Os resultados do tipo I estão dependentes da dimensão das amostras, não devendo ser utilizado para este caso.

Devido ao elevado número de fatores que poderão contribuir para o sucesso de uma campanha, a análise estatística constitui um processo importante para a análise dos seus efeitos e relevância. Kalwani e Yim (1992), por exemplo, analisam o impacto da frequência de promoções realizadas numa determinada marca e a quantidade de desconto emitida no preço expectável do ponto de vista dos consumidores.

## 2.4 Decomposição de efeitos promocionais

Segundo Gupta (1988), o impacto de uma promoção pode ser analisado decompondo a elasticidade de vendas promocionais em três efeitos obtidos a partir do ponto de vista do consumidor. Estes efeitos são a troca de marca, a diminuição do intervalo de tempo entre compras e o *stockpiling*, em que o consumidor aproveita a promoção para adquirir mais do

que necessita naquele momento. O seu estudo indica que mais de 84% da elasticidade de vendas é devido à troca de marcas, 14% devido à aceleração de compras e apenas 2% são atribuídos ao *stockpiling*.

Contudo, como estes valores foram calculados com base na categoria de café apenas, é possível que o efeito de *stockpiling* seja significativamente superior, em categorias onde o armazenamento de produtos é mais fácil.

Bell et al. (1999) dividem o impacto promocional em procura primária e secundária. A procura primária representa a aceleração de compras (tanto pelo aumento de quantidade como pela diminuição do tempo entre compras), enquanto a troca de marcas se enquadra na procura secundária. Os autores analisam o incremento de vendas em 13 categorias de produtos diferentes, estudando a relação dos fatores categoria, marca e tipo de consumidor na procura primária e secundária separadamente. Concluem que, em média, 75% da elasticidade de vendas é graças à procura secundária (troca de marcas) e a procura primária representa 25% do incremento total.

Estes resultados permitem concluir que apesar de a procura secundária representar a maior parte da elasticidade total, a procura primária apresenta também um peso significativo. A procura secundária, mais concretamente a troca de marcas, é um exemplo de canibalização. Para um retalhista, a canibalização acontece quando o aumento de vendas de um artigo prejudica as vendas de outros, podendo estes pertencer à mesma categoria e marca, a marcas diferentes ou até a lojas distintas (Pancras et al. 2012).

Mais tarde, Heerde et al. (2003) esclarecem que o aumento da procura primária constitui a maior parte do impacto total de uma promoção. Na determinação da elasticidade, os autores assumem que as vendas da categoria se mantêm constantes. Considerando o seu aumento, apenas 33% da variação total de vendas é explicada pela troca de marcas (procura secundária), pelo que a procura primária (expansão da categoria e *stockpiling*) é a principal fonte de incremento de vendas.

Ailawadi et al. (2006) analisam tanto o impacto de vendas como os lucros provenientes de ações promocionais de um retalhista, examinando as suas relações com fatores que integram as características das promoções, marcas, categorias e lojas em campanha.

Os autores decompõem o impacto de vendas e lucros em variações dentro da marca promovida, entre marcas, entre categorias e entre lojas. Além do incremento promocional dado à própria categoria, estuda-se o *Halo Effect* (o contágio positivo nas vendas de outras categorias). Os autores determinaram que a maior parte da variação é causada dentro da própria marca (62% da variação total de vendas e 67% no caso dos lucros). É também de salientar que 30% da variação total de vendas é originária do efeito positivo de contágio (*Halo Effect*).

Nesta dissertação apenas é determinado o impacto na procura primária, ou seja, o aumento das vendas apenas dos produtos diretamente em promoção.

O estudo realizado por Ailawadi et al. (2006) indica também que, em média, o impacto nos lucros é negativo, sendo explicado pela diminuição substancial da margem habitual. Conclui-se também que muitos dos fatores analisados geram impactos opostos nas vendas e lucros. Assim sendo, o retalhista terá de efetuar as suas decisões promocionais baseadas num compromisso entre as receitas e o seu lucro.

No presente trabalho, somente é quantificada a diferença das vendas líquidas do retalhista, pelo que uma análise mais aprofundada tendo adicionalmente em conta o impacto nos seus lucros poderia ser útil. de Miranda (2012), por exemplo, desenvolve uma metodologia para a quantificação do impacto promocional de um retalhista especializado dividindo-o em três métricas: variação de vendas, cesta média e número de transações.

Na identificação dos fatores que influenciam a procura durante as ações promocionais, Ramanathan e Muyldermans (2010) analisam um conjunto de características que potencialmente influenciam as vendas. Para além das características promocionais, como a quantidade e tipo de desconto, estudam outros fatores como a temperatura, a sazonalidade, dias especiais (férias e feriados) e preferências dos consumidores (os artigos com maiores volumes de vendas são melhor classificados).

Apesar de os resultados confirmarem a relevância das características promocionais, a influência dos restantes fatores apenas é significativa para algumas famílias de produtos estudadas. Conclui-se que os produtos devem ser promovidos de forma diferente tendo em conta a sua tipologia.

## 2.5 Análise crítica

O estado atual da literatura promocional compreende diversos estudos sobre a decomposição dos seus efeitos e a previsão de vendas para períodos em campanha. Apresenta-se nesta dissertação uma metodologia específica para a análise e previsão de impactos de campanhas de um retalhista especializado. As características únicas do retalhista obrigam a uma adaptação dos métodos já desenvolvidos.

Uma das suas particularidades é a componente sazonal da maior parte dos seus artigos, que se encontram integrados em coleções. Deste modo, a análise ao impacto promocional deverá ser feita a um nível de detalhe superior da estrutura mercadológica. A intensa frequência promocional e um âmbito alargado a todos os níveis de detalhe da estrutura mercadológica requerem o desenvolvimento de uma metodologia standardizada que possa ser aplicada de uma forma o mais automática possível.

Neste projeto, o impacto promocional é definido como a diferença de vendas líquidas para os artigos e período em campanha apenas. A análise do impacto de campanhas em diferentes produtos e em períodos imediatamente posteriores à promoção permitiriam analisar outros efeitos que a literatura apresenta como relevantes, principalmente para um retalhista. De modo adicional, a inclusão na análise de outras métricas como a cesta média e o número de transações complementaríamos o estudo realizado.

### 3 Definição do problema

A Sport Zone pratica inúmeras campanhas ao longo de todo o ano. A sua oferta promocional compreende vários tipos de mecânicas e abrange todo o universo de lojas e artigos.

Adicionalmente, são efetuadas promoções em todos os níveis da sua estrutura mercadológica, desde campanhas em toda a loja à redução temporária do preço de um artigo. O facto de as campanhas poderem ocorrer simultaneamente nos mesmos períodos e atingirem diferentes níveis da sua estrutura mercadológica faz com que se possam identificar sobreposições de descontos em muitos artigos, podendo este facto acontecer propositadamente ou não.

Dada a complexidade deste sistema, a avaliação do impacto promocional resulta num processo de difícil execução e ao mesmo tempo fundamental para que exista uma compreensão objetiva dos seus efeitos tanto ao nível de vendas como margens.

O desenvolvimento de uma metodologia uniforme, capaz de quantificar e analisar o impacto de todo o universo de campanhas, permitirá aumentar o âmbito atual da análise promocional. O estudo dos fatores que poderão influenciar o desempenho das campanhas é um exemplo claro da relevância e potencialidade deste projeto. O seu objetivo último é, em adição à análise de fatores, a previsão do impacto promocional traduzido em aumento de vendas dos artigos em campanha.

A análise de fatores e a estimação do seu impacto fornecem a base para uma melhor decisão dos agentes envolvidos no desenho das campanhas. No presente capítulo, serão introduzidos os principais intervenientes na criação de campanhas na Sport Zone, assim como os conceitos e nomenclaturas de maior relevância no contexto promocional da empresa.

#### 3.1 Estrutura organizacional

A Sport Zone opera tanto em solo nacional como internacional. O seu negócio pode ser dividido em orgânico, para as lojas próprias da empresa, e franqueado. Do negócio orgânico fazem parte todas as lojas de Portugal Continental, Madeira e Espanha. As direções de vendas orgânicas estão divididas em Portugal (79 lojas), península de Espanha (19 lojas) e Canárias (13 lojas). Das 79 lojas orgânicas de Portugal, quatro apresentam um formato de *outlet*.

As ações promocionais são geridas independentemente por cada direção de vendas. Apesar das lojas localizadas nos Açores serem franqueadas, existe um contacto próximo com o negócio orgânico. As campanhas que abrangem todas as lojas de Portugal incluem usualmente as franqueadas dos Açores.

A sua gama de artigos abrange tanto marcas de fornecedores externos como marcas próprias, desenvolvidas pela empresa. O tipo de marca própria é usualmente caracterizado pelo posicionamento dos artigos em primeiro preço.

A Figura 1 apresenta a hierarquia principal da estrutura mercadológica atual da Sport Zone e um exemplo para cada posição. Os artigos dividem-se em 8 unidades de negócio, sendo depois repartidos de acordo com a sua classificação. A Figura 2 apresenta as unidades de negócio da empresa. A Figura 1 do Anexo A apresenta as categorias da unidade de negócio de

Fitness e Essentials, a título de exemplo. Cada unidade de negócio tem a sua própria estrutura. Por exemplo, na unidade de negócio de Casual, a distinção de género é feita logo na categoria, em contraste com o exemplo da Figura 1, em que a mesma é efetuada na subcategoria. Cada artigo ainda pode ser subdividido em artigo pai e filho, em que o pai representa toda a gama de tamanhos do artigo e o filho especifica um tamanho particular.

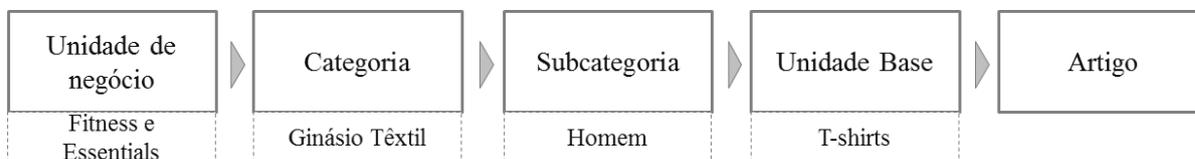


Figura 1 - Hierarquia principal da estrutura mercadológica da Sport Zone

As unidades de negócio desenham as campanhas que abrangem a sua gama de artigos. Adicionalmente, são também desenvolvidas, por uma equipa independente, denominada de Desenvolvimento Comercial, campanhas transversais às unidades de negócio. Folhetos promocionais e campanhas em toda a loja são exemplos de promoções transversais. São ainda realizadas campanhas segmentadas pela equipa de Marketing.

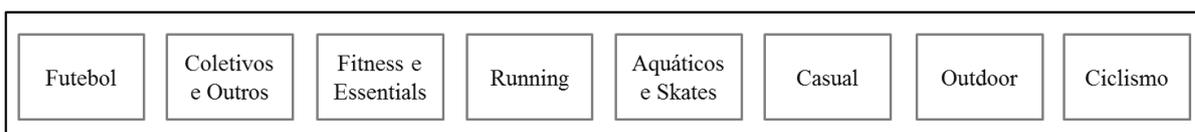


Figura 2 - Unidades de negócio da Sport Zone

### 3.2 Parametrização de campanhas

Num momento inicial, esclarece-se a definição de campanha, para efeitos de parametrização no sistema. As ações promocionais são divididas hierarquicamente em três níveis: evento, campanha e promoção.

Os eventos integram o nível mais alto da hierarquia promocional, contemplando conjuntos de campanhas que poderão fazer sentido agrupar. Os meses temáticos são um exemplo usual de eventos parametrizados. Durante um período aproximado de um mês, há uma aposta significativa numa unidade de negócio, habitualmente, traduzida em investimentos na comunicação, tanto em publicidade como na exposição dos artigos em loja, e em diversas ações promocionais. Quando são realizadas pequenas campanhas que não se enquadram em nenhum evento especial, considera-se que pertencem ao evento “campanhas genéricas”.

Para definir uma campanha, utilize-se, a título de exemplo, o “mês do *Running*”, um dos meses temáticos já estabelecidos. Dentro deste evento, efetuam-se várias ações promocionais concretas, abrangendo um conjunto específico de lojas e um período definido. Estas ações são denominadas de campanhas. Um exemplo de uma campanha inserida no “mês do *Running*” seria “mês do *Running*: toda a marca Nike”.

Dentro de cada campanha, definem-se as várias mecânicas promocionais que abrangem diferentes grupos de artigos. Estas ações são designadas por promoções. A cada promoção pertencem um conjunto de artigos e uma mecânica promocional específica. No decorrer desta secção, clarifica-se a definição de mecânica promocional. A parametrização torna-se completamente definida quando especificados o calendário, artigos e lojas abrangidas por cada mecânica.

É importante salientar que, apesar de existir a distinção na parametrização entre os termos campanha e promoção, os mesmos são empregados de igual forma ao longo da dissertação, utilizando o sentido lato destes conceitos.

A mecânica promocional abrange uma série de parâmetros, compreendendo o tipo de promoção, a forma como o desconto é emitido e a quantidade de desconto, entre outros. Os

três principais tipos de promoção são *Multi Units*, *Single Items* e *Mix and Match*. Para além destes, existem outros como promoções de patamar, por exemplo, que se consideram residuais.

As promoções *Multi Units* são utilizadas quando é aplicado um desconto comum, percentual ou absoluto, a um conjunto de artigos. O desconto aplicado pode ser emitido por duas vias, através de desconto direto ou desconto em cartão. O desconto direto é aplicado no momento da compra, enquanto o desconto em cartão é armazenado no cartão de cliente no momento da compra e rebatido apenas numa compra futura. A este desconto associa-se o conceito de taxa de rebate, que representa a percentagem de clientes que obteve o desconto em cartão e efetivamente o utilizou futuramente.

A quantidade de desconto a aplicar em relação ao preço original pode ser parametrizada de duas maneiras, indicando a redução absoluta ou designando uma percentagem. *Single Items* refere-se às reduções de preço durante um determinado período de tempo. O seu nome advém do facto de que a parametrização destas promoções é necessariamente efetuada ao nível do artigo pai, sendo o preço uma característica única de cada artigo.

Por último, utiliza-se *Mix and Match* para as promoções do tipo “leve x pague y”.

Quanto ao universo de clientes abrangidos pelas campanhas, são definidos dois tipos: as campanhas genéricas, estendidas a todos os clientes, e segmentadas, em que apenas um conjunto restrito de clientes tem acesso à promoção, através dos cartões de cliente.

O âmbito da análise efetuada no presente projeto é definido no capítulo 4.

## 4 Metodologia para análise de campanhas

A metodologia desenvolvida para a análise de campanhas é apresentada neste capítulo. A Figura 3 apresenta o quadro global do projeto realizado. O principal objetivo do projeto é a previsão do aumento de vendas de uma campanha, de acordo com as suas características, para auxiliar o processo de desenvolvimento de novas campanhas.

Deste propósito adveio o primeiro objetivo, o apuramento dos impactos de campanhas históricas. Primeiramente, é efetuado um levantamento de uma base de dados de campanhas já concluídas. De seguida, determina-se o impacto nas vendas para cada campanha. Para isso, comparam-se as vendas reais da campanha com um *baseline*, que representa as vendas que, teoricamente, se teriam realizado se a campanha não existisse.

Os impactos históricos determinados servem de base para o segundo objetivo, a simulação de impactos de campanhas futuras. Para isso, são analisados os fatores que causaram maior variação nas vendas das campanhas passadas. De acordo com esses fatores, é efetuada uma previsão do que será o aumento de vendas esperado.

Utiliza-se a mesma metodologia para o cálculo de impactos históricos no acompanhamento de campanhas a decorrer. O acompanhamento é feito com base na comparação entre as vendas atuais, o *baseline* e um período comparável.

Paralelamente, foram desenvolvidas duas ferramentas que constituem a aplicação prática da metodologia na empresa.

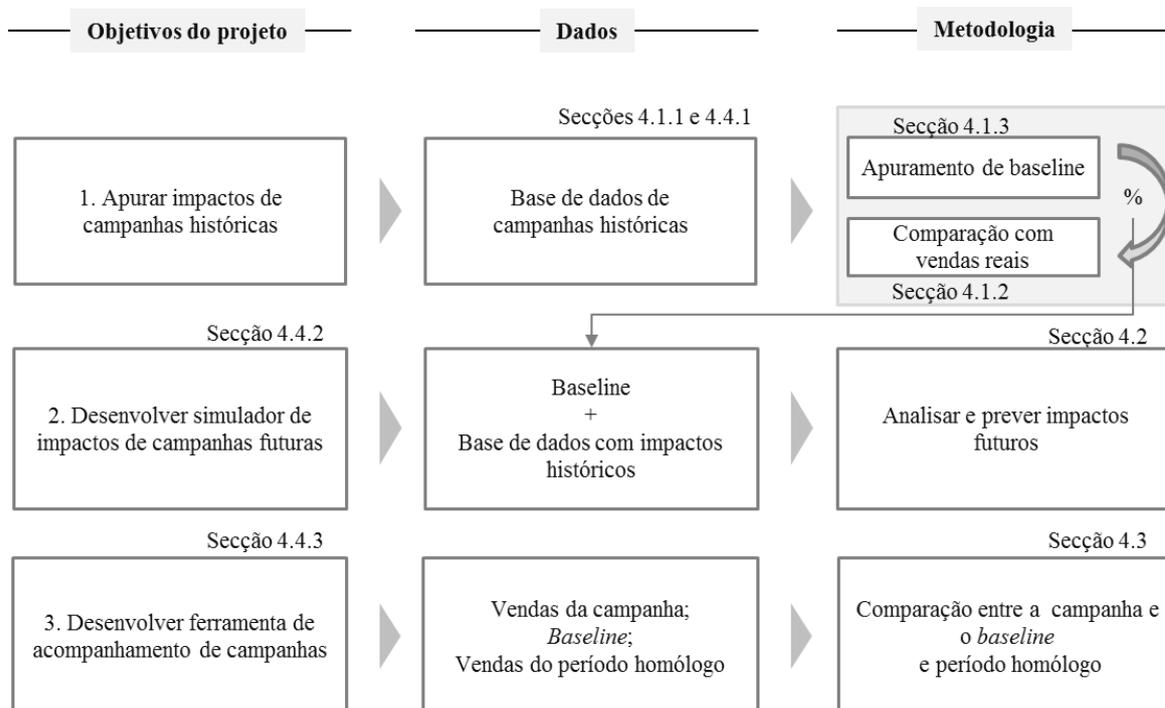


Figura 3 - Quadro global do projeto realizado

## 4.1 Apuramento de impactos históricos

### 4.1.1 Dados

Numa primeira fase, construiu-se uma base de dados contendo informações sobre campanhas realizadas anteriormente. Os dados utilizados para a posterior análise dos impactos partiram de uma filtragem à base de dados inicialmente recolhida (Figura 1 do Anexo B). Destaca-se nesta secção a estrutura desenvolvida para a base de dados e o seu âmbito. A indicação dos filtros utilizados para a análise encontra-se na secção 4.2.1.

O horizonte temporal definido para o histórico de campanhas corresponde a dois anos. Um período temporal mais alargado seria mais indicado para obter uma análise a níveis de maior detalhe e com maior robustez. Não obstante, o tempo exigido para obter dois anos de informação já foi, por si só, demasiado extenso.

Quanto ao âmbito do tipo de campanhas, apenas se extraíram campanhas do tipo *Multi Units*. As campanhas *Multi Units*, em que é aplicado um desconto comum a um conjunto de artigos, revelaram-se as únicas em que era possível, com fiabilidade, determinar o desconto aplicado.

No caso das *Single Items*, apesar de existir informação sobre a redução absoluta de preço registada para cada campanha, não é possível obter com credibilidade o preço à qual essa redução foi aplicada. No entanto, a dimensão deste tipo de campanhas é comparável às *Multi Units* e constitui, por essa razão, uma análise importante que deve ser conduzida no futuro. Os restantes tipos de campanhas, dada a sua pequena dimensão e complexidade acrescida, foram igualmente excluídos da extração e, conseqüentemente, da análise.

Apenas as campanhas genéricas foram consideradas. A análise de campanhas segmentadas é usualmente realizada através da utilização de grupos de controlo. As campanhas de Espanha não foram consideradas para o projeto. Pois, para além de serem geridas independentemente, contêm características significativamente diferentes às promoções realizadas em Portugal.

No que toca às campanhas de Portugal, foram desconsideradas as campanhas em *outlets*, dado que o seu objetivo está usualmente relacionado com o escoamento de inventário e não com a rentabilidade. As restantes lojas foram todas consideradas, incluindo as lojas *online* e dos Açores (apesar das lojas dos Açores serem franqueadas, são usualmente incluídas, assim como a loja *online*, nas campanhas que abrangem todas as lojas orgânicas). O comportamento promocional da loja *online* poderá ser diferente das restantes. O efeito da loja nos impactos calculados deveria ser avaliado.

Em relação à estrutura mercadológica, não foram impostas quaisquer restrições. Todos os artigos foram considerados. Na base de dados, recorreu-se à agregação da estrutura mercadológica ao nível da unidade base.

O nível mais detalhado da parametrização de cada campanha envolve sempre a conjugação de três componentes: dia, artigo e loja. Se não se procedesse a algum tipo de agregação, a combinação dos três fatores teria uma dimensão demasiado extensa. Considere-se  $n_D$  como o número de dias da campanha,  $n_A$  o número de artigos e  $n_L$  o número de lojas parametrizadas. O número de combinações totais da campanha seria dado por  $n_D * n_A * n_L$ . A escolha da agregação torna-se assim uma decisão crucial para a dimensão e tratamento da base de dados.

Outro fator que a agregação de dados condiciona é a robustez do cálculo do impacto. Esta robustez baseia-se no erro de previsão associado à determinação do *baseline*, explicado na secção 4.1.3, que é posteriormente comparado às vendas reais da campanha. Quanto maior o nível de agregação, menor será o erro de previsão. Contudo, um nível de detalhe mais agregado afeta negativamente o pormenor a que podem ser efetuadas as análises aos dados.

A agregação da estrutura mercadológica ao nível da unidade base permitiu reduzir significativamente a dimensão da base de dados. Para além da dimensão, a decisão baseou-se

no facto de que a estrutura da Sport Zone se baseia em coleções sazonais e os seus artigos estão em constante alteração. Numa tentativa de incorporar a questão da elasticidade de preço, separou-se cada unidade base por marca. É de esperar que no espaço de uma unidade base, os artigos da mesma marca se situem na mesma categoria de preço.

No que diz respeito à dimensão temporal, a agregação foi efetuada ao período total da campanha. Por fim, a base de dados agrega os resultados das campanhas em todas as lojas parametrizadas.

No capítulo 3, enunciou-se a hierarquia utilizada para as ações promocionais. Optou-se pelo registo ao nível da campanha, separando depois pelas diferentes mecânicas. A razão desta escolha deu-se pela forma como são parametrizadas as promoções em desconto em cartão. Cada promoção é necessariamente parametrizada duas vezes para abranger todo o universo de clientes, dividido pelos clientes que possuíam o antigo cartão e o mais recente.

Em conclusão, cada registo único da base de dados resulta da combinação entre campanha, mecânica promocional, unidade base e marca.

Para cada combinação, foram registadas diversas métricas associadas à ação promocional. As vendas líquidas representam a métrica mais relevante para o âmbito do projeto, servindo de base para a determinação do aumento de vendas devido à campanha. As vendas brutas, margem líquida e quantidade vendida também foram registadas.

Visto que a base de dados agrega os artigos à unidade base, registaram-se o número de artigos parametrizados e o número de vendidos. Na mesma lógica, registaram-se também as contagens das lojas.

Na Figura 2 do Anexo B é apresentado um exemplo em forma de tabela da base de dados desenhada.

#### 4.1.2 Impacto

Anteriormente, os resultados das grandes campanhas eram analisados comparando as vendas e margens, caso existissem, com as mesmas campanhas nos anos anteriores (é o caso dos meses temáticos). A maior parte das campanhas de menor dimensão não eram analisadas com pormenor.

Contudo, a comparação com campanhas anteriores apresenta algumas desvantagens que levaram à consideração da criação de um processo que comparasse as vendas reais da campanha com o que seria esperado vender no mesmo período se não existisse nenhuma campanha.

As análises efetuadas requeriam a criação de um período comparável, um método envolto em alguma subjetividade. Raramente era possível identificar uma campanha anterior que tivesse sido efetuada nos mesmos moldes. Por exemplo, quando a dimensão do período diferia da dimensão da campanha analisada, era necessário recorrer a algum processo de extrapolação. Além das questões de calendário, as lojas e os artigos parametrizados dificilmente se mantinham.

Perante a necessidade de quantificar o impacto das campanhas de uma forma mais objetiva e automática, foi criado um método para determinar o impacto da campanha sem requerer a definição de uma campanha homóloga.

O impacto foi definido como o aumento relativo (ou diminuição) das vendas líquidas da campanha face a um valor de referência, denominado de *baseline* (Equação 1). No âmbito deste projeto, o *baseline* representa o valor das vendas líquidas caso a campanha não existisse.

$$\text{Impacto}(\%) = \frac{\text{Vendas Líquidas} - \text{Baseline}}{\text{Baseline}} \times 100 \quad (1)$$

O *baseline* é um valor teórico, não sendo possível mensurá-lo. Desta forma, torna-se indispensável a criação de um modelo de previsão que se aproxime do que seriam as vendas líquidas sem os efeitos da campanha. A utilização de um modelo de previsão pressupõe a inevitabilidade da existência de um erro associado à previsão (Box e Draper 1987). Este problema é abordado com maior detalhe no capítulo 5.

Como foi referido na secção 4.1.1, foi tido em consideração um nível de agregação da base de dados que permitisse robustez suficiente para reduzir o erro associado à previsão do *baseline*. A abordagem utilizada para o cálculo do *baseline* é apresentada na secção 4.1.3.

O impacto é apenas determinado para o período em que a promoção está efetivamente a ocorrer. Da mesma forma, só são analisadas as vendas nas lojas e artigos parametrizados. Por este motivo, não serão tidos em conta possíveis efeitos de *stockpiling*, contágios ou canibalizações.

#### 4.1.3 Baseline

Determinou-se o *baseline* com base nas vendas das três semanas anteriores ao início de cada campanha (Figura 4). A decisão por uma janela temporal de três semanas teve em conta o facto de ser ampla o suficiente para permitir um *baseline* robusto e, ao mesmo tempo, não comprometer em demasia o custo de aquisição da informação. Este custo está relacionado com a elevada dimensão da base de dados e o tempo de processamento necessário para obter as vendas históricas. Um incremento do horizonte temporal levaria a uma diferença significativa no tempo de obtenção dos dados, que se mostrou um obstáculo ao projeto.

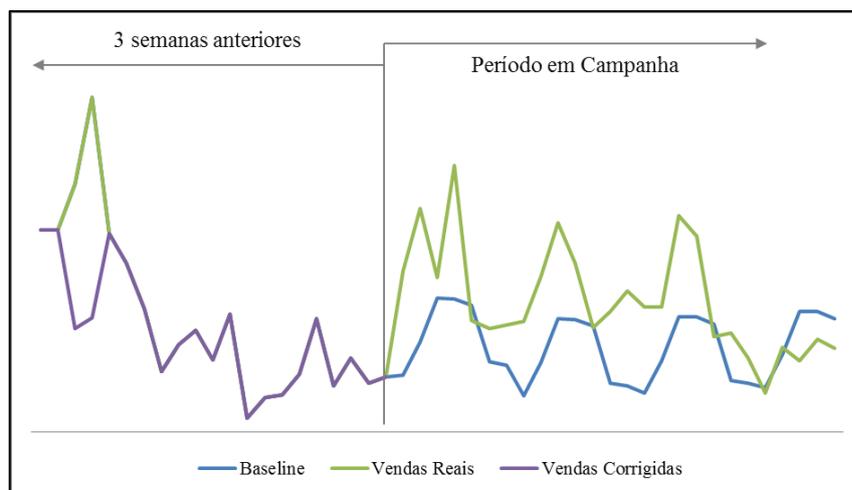


Figura 4 - Janela temporal utilizada para o *baseline*

Sendo o *baseline* uma previsão do que seriam as vendas sem efeitos promocionais, as vendas históricas utilizadas para o cálculo do mesmo foram sujeitas a um tratamento prévio, de forma a não considerar possíveis *outliers* (observações atípicas que apresentam uma discrepância em relação à generalidade das observações, podendo comprometer a análise efetuada) (Hodge e Austin 2004).

Os *outliers* podem surgir por variados motivos. No contexto do projeto, destacam-se os incrementos de vendas devido a campanhas promocionais anteriores, feriados e outros períodos especiais ou até períodos sem vendas de determinados artigos, graças à falta de inventário, por exemplo.

Foi desenvolvido um processo automático para contornar estes efeitos. A abordagem utilizada consistiu na substituição pela média de observações que se encontrassem fora de um intervalo de confiança do período considerado. Este processo é efetuado em duas iterações. Após a substituição das observações na primeira iteração, novos intervalos de confiança são computados e o processo é repetido (Figura 5).

A Equação 2 retrata a forma como os intervalos de confiança foram calculados. Aplicou-se uma amplitude de quatro desvios padrões, centrados pela média das observações.  $\mu$  representa a média e  $\sigma$  o desvio padrão das vendas das 3 semanas anteriores a cada campanha.

$$\text{Intervalo de confiança} = \mu \pm 2\sigma \quad (2)$$

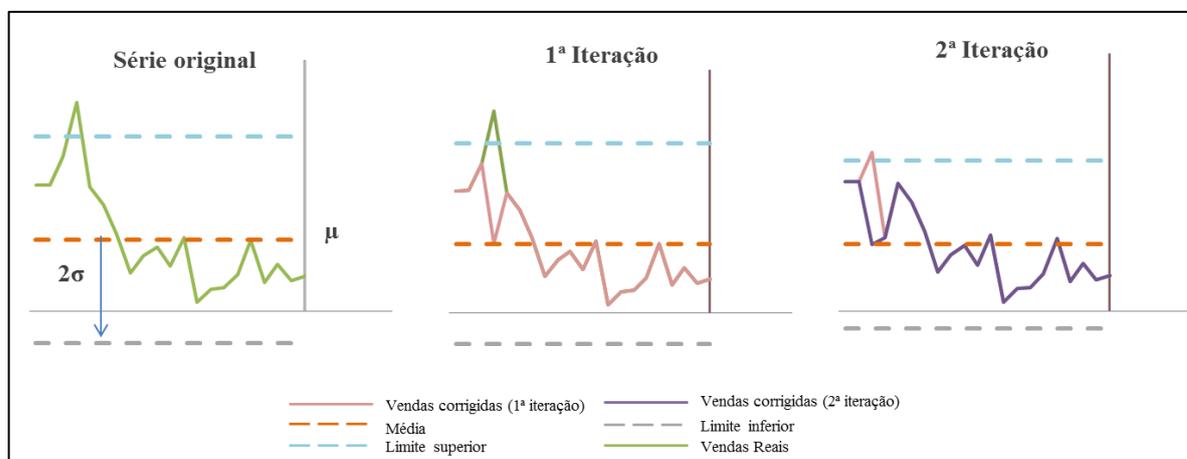


Figura 5 - Correção de outliers no cálculo do *baseline*

Após o tratamento de dados, procede-se o cálculo do *baseline*. A Figura 6 expõe de forma geral a abordagem utilizada. Os *baselines* de cada dia do período em campanha são determinados individualmente, sendo posteriormente somados, resultando no *baseline* total da campanha (Equação 3).

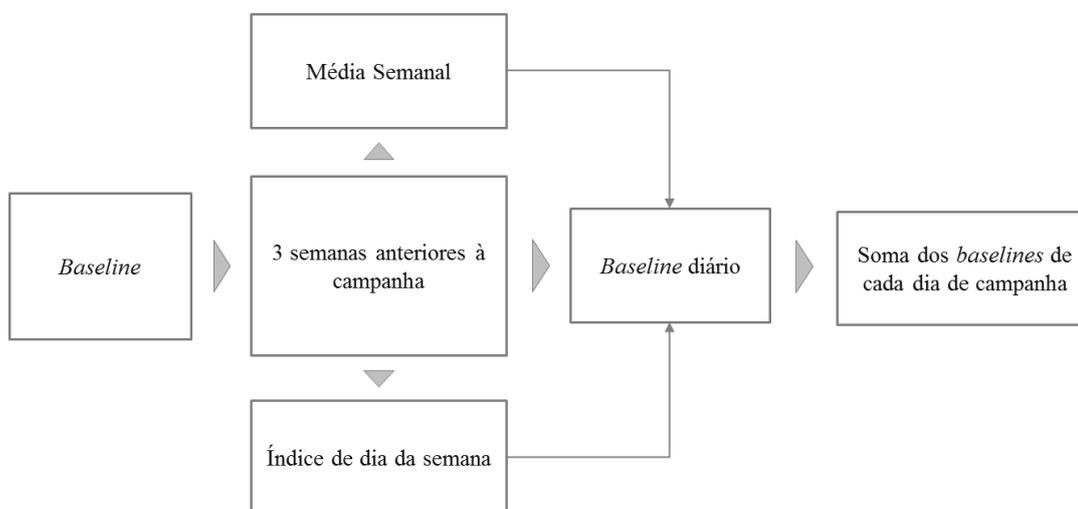


Figura 6 - Diagrama da abordagem utilizada para o cálculo do *baseline*

Cada dia é definido por uma semana  $s$  e o dia da semana  $d$  correspondente.  $n_s$  representa o número total de semanas da campanha e  $n_d$  o número de dias da última semana (todas as semanas anteriores são completas, com 7 dias cada). O *baseline* diário é calculado tendo em conta as duas componentes: semana e dia da semana.  $VS$  representam as vendas semanais e  $VD$  as vendas diárias.

A componente semanal resulta da média móvel, com uma janela temporal de três semanas anteriores, das vendas semanais (Equação 4). A expressão “média móvel” advém da janela temporal a que é aplicada a média, que acompanha a semana que está a ser determinada. Por exemplo, a média móvel de uma semana  $n$  teria como horizonte temporal as três semanas anteriores  $n-1$ ,  $n-2$  e  $n-3$ , independentemente da sua posição. A principal vantagem deste método reside no acompanhamento da tendência das vendas das últimas semanas, verificando-se a sua utilidade para períodos de campanhas mais longos. Na Figura 7 é exposta a metodologia empregada.

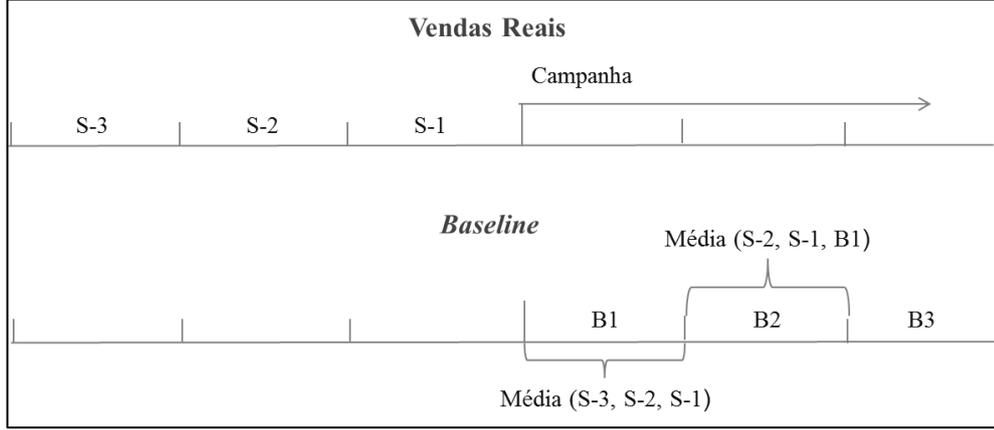


Figura 7 - Metodologia para o cálculo da média móvel semanal

O *baseline* diário divide a componente semanal pelos sete dias de igual forma. Adicionalmente, é aplicado um índice adicional  $S_d$  que, dentro de cada semana, diferencia os seus dias (Equação 5). A necessidade deste índice provém de uma forte sazonalidade semanal verificada no retalho. Por exemplo, as vendas durante o fim de semana são significativamente superiores comparativamente aos dias úteis.

O índice  $S_d$  de cada dia da semana é constante para todas as semanas em período de promoção e tem por base as vendas das 3 semanas anteriores à campanha. Para esta componente, utilizaram-se as vendas reais, sem a eliminação de *outliers*, dado que, para cada índice, só se tem em consideração três observações.

A técnica utilizada para o cálculo do índice diário foi retirada do modelo aditivo de decomposição clássica. Para cada dia dentro das três semanas, é computada a diferença  $D_{w,d}$  entre as vendas reais do dia e a média móvel diária (Equação 6).  $w$  representa cada uma das 3 semanas anteriores. Salienta-se que esta média é diferente da utilizada para determinar a componente semanal. A média móvel diária tem uma janela temporal de uma semana, sete dias, e é centrada no dia analisado (Equação 7). O índice de cada dia da semana  $S'_d$  é dado pela média das diferenças  $D_{w,d}$  desse dia (Equação 8).

Depois de obtidos todos os índices  $S'_d$ , é aplicado um ajustamento aos mesmos para que a sua soma seja nula, obtendo o conjunto final  $S_d$  (Equação 9). O ajuste é dado pela subtração da média dos índices  $S'_j$ , sendo  $j$  o dia da semana. O facto de a soma dos índices ser nula faz com que, no caso das semanas completas, a componente sazonal não tenha efeito, já que o *baseline* final é a soma dos *baselines* diários. Ou seja, na prática, o índice diário só produz efeito na última semana da campanha e se esta for incompleta.

$$Baseline\ Total = \sum_{s=1}^{n_s-1} \sum_{d=1}^7 Baseline_{s,d} + \sum_{d=1}^{n_d} Baseline_{n_s,d} \quad (3)$$

$$Média\ Móvel\ Semanal_s = \frac{1}{3} \times \sum_{i=s-3}^{s-1} VS_i \quad (4)$$

$$Baseline_{s,d} = \frac{1}{7} \times Média\ Móvel\ Semanal_s + S_d \quad (5)$$

$$D_{w,d} = VD_{w,d} - Média\ Móvel\ Diária_{w,d} \quad (6)$$

$$Média\ Móvel\ Diária_d = \frac{VD_{d-3} + VD_{d-2} + VD_{d-1} + VD_d + VD_{d+1} + VD_{d+2} + VD_{d+3}}{7} \quad (7)$$

$$S'_d = \frac{1}{3} \times \sum_{w=1}^3 D_{w,d} \quad (8)$$

$$S_d = S'_d - \frac{1}{7} \sum_{j=1}^7 S'_j \quad (9)$$

## 4.2 Previsão de impactos futuros

Depois de determinado o impacto para cada registo da base de dados (combinação de campanha, mecânica, unidade base e marca), deu-se início ao próximo objetivo do projeto: a previsão do impacto de uma campanha futura tendo em conta um conjunto de fatores que a caracteriza. Analisaram-se, para isso, alguns fatores que poderão causar uma forte variação no impacto. Finalmente, estimam-se os impactos de acordo com os fatores analisados, de modo a complementar a tomada de decisão no desenvolvimento de campanhas futuras.

### 4.2.1 Análise

Antes da análise propriamente dita, procedeu-se a uma filtragem da base de dados inicial. O tratamento da informação foi uma etapa relevante no processo. Esta fase teve como propósito a seleção restrita mas robusta de registos que não comprometessem a fiabilidade do estudo.

Os filtros criados tiveram o propósito de retirar da base de dados as campanhas desenquadradas com a análise, incoerências na parametrização e todos os registos que não providenciassem confiança necessária para garantir um erro oriundo do *baseline* reduzido. Foram também excluídos todos os impactos que apresentassem uma discrepância significativa face ao que seria previsível. Apresentam-se assim os principais pressupostos e filtros utilizados.

As campanhas de saldos não foram consideradas na análise. Foram também desconsideradas as campanhas com apenas uma loja parametrizada, por forma a evitar aberturas ou remodelações de loja e reações à concorrência. Apenas os descontos parametrizados em percentagem foram estudados. A quantidade de reduções absolutas de preço nas campanhas *Multi Units* é residual.

A base de dados contempla somente promoções que apresentaram vendas no período em campanha. Quanto ao *baseline*, consideraram-se os registos que apresentassem mais de 20€ em vendas, por forma a evitar períodos em que, por alguma razão, não existiram vendas significativas previamente à campanha, inflacionando o impacto. Por último, eliminaram-se os registos que apresentavam impactos negativos.

Após a aplicação da filtragem descrita, verificou-se uma presença clara de observações atípicas. Na Figura 1 do Anexo C, é apresentado o processo realizado para a remoção destes *outliers*. No final, ignoraram-se os registos com impacto superior a 400%.

A maior parte dos registos de desconto direto corresponde a campanhas de saldos e aberturas de loja. A dimensão sobrança de registos não é suficiente para analisar com credibilidade o seu impacto. Por essa razão, estudaram-se apenas os impactos de mecânicas com desconto em cartão.

O cálculo dos impactos históricos permitiu a montagem de uma base inicial sólida para o estudo do impacto promocional nas vendas. A análise efetuada no decorrer do projeto constituiu o ponto de partida na análise de campanhas da empresa e possibilitou a identificação de alguns fatores que afetam significativamente o impacto. A quantidade de desconto percentual emitida, o tipo de marca, a tipologia e o género dos artigos são os fatores de maior relevo do estudo realizado.

Utilizou-se a análise de variância de efeitos fixos para a identificação dos fatores que afetam significativamente o impacto promocional. Foi utilizado o *software Minitab* para a análise. As condições impostas pela análise de variância são expostas no capítulo 2. Para comparações entre apenas duas populações, utilizou-se o teste de hipóteses como inferência estatística.

As amostras utilizadas para a análise de variância apresentam dimensões diferentes, já que não foram retiradas de uma experiência planeada. Utilizou-se o tipo III dos mínimos quadrados para a estimação de parâmetros. Esta questão é abordada com maior detalhe no

capítulo 2. O *software Minitab* utiliza o método de Welch na análise de variância, pelo que o requisito de variância constante não precisa de ser verificado. Para esta análise, utilizaram-se apenas amostras com mais de 30 de registos, para que a condição de normalidade pudesse ser ignorada. A independência dos erros está relacionada com o processo de recolha de dados. A verificação da condição foi efetuada a partir dos gráficos de dispersão dos erros (Figura 2 do Anexo C). Os gráficos aparentam representar a aleatoriedade dos resíduos.

#### 4.2.2 Previsão

Com vista à simulação do aumento nas vendas de campanhas futuras, utilizaram-se duas técnicas para o desenvolvimento de modelos de previsão para o impacto. O principal objetivo da criação dos modelos era o estabelecimento de uma relação explícita de dependência entre os fatores que caracterizam as campanhas e o impacto. Para este efeito utilizaram-se as técnicas de regressão múltipla e árvores de regressão, através do *software R*.

Para controlar a dimensão de registos utilizada para cada modelo, construiu-se uma nova estrutura mercadológica, de maneira a que cada modelo fosse construído a partir de uma base com pelo menos cem registos. Por exemplo, na unidade de negócio de Fitness e Essentials, a dimensão de registos de campanhas é significativamente superior às restantes. Assim sendo, foi possível adequar modelos a níveis de detalhe mais pormenorizados.

Vários fatores foram incluídos nos modelos como ponto de partida. Dentro destes fatores, incluem-se tanto variáveis contínuas como categóricas. A percentagem de desconto emitido, o tipo de marca, os números de dias, artigos e lojas e trimestre da campanha foram os principais fatores estudados.

No caso do método de regressão múltipla, utilizou-se um procedimento automático para a inclusão das variáveis independentes mais significativas no modelo. Para esse fim foi utilizado o método *stepwise* bidirecional, com o critério de seleção AIC. O método bidirecional é uma combinação das técnicas *forward* e *backward*. O método *forward* adiciona, a cada passo, uma variável ao modelo já existente. Por sua vez, o método *backward* inicia com um modelo que inclui todas as variáveis e, a cada passo, retira a variável que causar menor variação no resultado final. O critério AIC é utilizado como regra de paragem para o método *stepwise*. Este estabelece um compromisso entre a qualidade do modelo e a sua complexidade. O seu principal objetivo é impedir que o modelo criado seja sobreajustado (Draper e Smith 1981).

As árvores de regressão também selecionam as variáveis mais significativas automaticamente. Dado que a relação entre as variáveis independentes utilizadas e a variável dependente não é conhecida, a utilização deste método tem como propósito a deteção de relações mais complexas e a apresentação visual do modelo desenvolvido, permitindo dar aos criadores de campanhas uma melhor noção do resultado possível (Figura 3 do Anexo C).

Os dois modelos utilizados não apresentaram resultados satisfatórios face à necessidade da empresa. No capítulo 5 é apresentado o desempenho de ambos. Por esta razão, em alternativa, construíram-se intervalos de confiança para o valor esperado dos impactos. Os intervalos foram calculados para diferentes combinações de alguns fatores que se mostraram significativos na análise estatística previamente realizada. A Equação 10 apresenta a fórmula utilizada para o cálculo dos intervalos. Estes são construídos a partir da média amostral  $\bar{X}$ , adicionando uma amplitude que representa o erro máximo da estimativa utilizada, com um nível de confiança  $(1-\alpha).100\%$ . Utilizou-se para este efeito um nível de confiança a 95%. A amplitude é baseada na distribuição *t* de *Student*.  $S$  representa o desvio padrão amostral e  $N$  o tamanho da amostra utilizada.

$$\bar{X} \pm t_{N-1}(\alpha/2) * \frac{S}{\sqrt{N}} \quad (10)$$

### 4.3 Acompanhamento de campanhas

O *baseline* desenvolvido para o cálculo do aumento de vendas associado às campanhas históricas pode ser igualmente aplicado para o acompanhamento de campanhas a decorrer. A metodologia para o cálculo do *baseline* é a mesma. A única diferença é registada na comparação entre o *baseline* e as vendas reais. Enquanto, no caso das campanhas históricas, o impacto foi determinado para o período total da campanha, o acompanhamento permite efetuar a mesma comparação durante todo o decorrer da campanha. Um acompanhamento detalhado poderá possibilitar a perceção, por exemplo, do declínio de uma campanha.

### 4.4 Aplicação prática

Nesta secção é apresentada a aplicação prática da metodologia desenvolvida. Os entregáveis à empresa podem dividir-se em 3 componentes: uma base de dados com informação sobre as campanhas históricas efetuadas e métricas relevantes, um simulador de impactos, que determina se o aumento de vendas da campanha compensará a perda de margem e, por último, uma ferramenta de acompanhamento para campanhas a decorrer.

#### 4.4.1 Base de dados

O estudo realizado durante o projeto constitui apenas o início de uma análise mais detalhada ao impacto de vendas de uma campanha. A base de dados construída consiste numa plataforma a que os agentes envolvidos na criação de campanhas terão acesso para perceber os impactos resultantes da combinação de vários fatores que caracterizam uma campanha.

A extração da base de dados e o cálculo do *baseline* para cada registo foram desenvolvidos, separadamente, em SQL (*Structured Query Language*). A determinação do *baseline* pode ser feita para qualquer tipo de campanha, dado que a única fonte utilizada são as vendas das três semanas anteriores à campanha.

O âmbito definido para a base de dados foi restrito o suficiente para que o tempo de extração não fosse demasiado demoroso. Além disso, teve em vista apenas fornecer informação para a extensão da análise efetuada. Um alargamento do âmbito da base de dados para campanhas *Single Items*, ou incluindo Espanha, por exemplo, juntamente com a aplicação do *baseline* e posterior cálculo do impacto será de fácil execução. Isto permitirá estender a análise efetuada e a aplicação das ferramentas desenvolvidas para outras campanhas. Foi também desenvolvida uma plataforma para facilitar o estudo do efeito de novos fatores no impacto e a construção de novos intervalos de confiança (Figura 1 do Anexo D).

#### 4.4.2 Simulador de impactos

O simulador de impactos tem como principal objetivo determinar se uma dada campanha terá impactos positivos, numa perspetiva de rentabilidade. O aumento de vendas previsto deve compensar a perda de margem percentual que advém do desconto. Adicionalmente, outros fatores como descontos e receitas comerciais, despesas de marketing e provisões libertadas podem igualmente ser tidos em conta.

Na Figura 2 do Anexo D, apresenta-se a folha de cálculo que retrata a lógica da ferramenta. O projeto desenvolvido permitiu dar resposta principalmente a dois campos da folha de cálculo: o *baseline* e o crescimento de vendas previstos para a campanha. O crescimento esperado de vendas é suportado por uma tabela de impactos construída a partir da estimação do valor esperado através de intervalos de confiança. A Figura 16 apresenta um exemplo da tabela desenvolvida. Os impactos apresentados são fictícios.

O *baseline* é calculado automaticamente, após a seleção dos artigos, lojas e período em campanha. Dado que a simulação de impactos lida necessariamente com períodos futuros, foi

definida uma nova metodologia para a sua determinação. Se uma campanha estiver a ser projetada e simulada um mês antes de iniciar, por exemplo, não é possível obter as três semanas anteriores de vendas, como na metodologia anterior. Assim sendo, desenvolveu-se uma nova abordagem baseada no método aditivo de decomposição clássica. Utilizando um horizonte temporal de pelo menos dois anos, o modelo utilizado é dividido em três componentes: tendência e sazonalidades semanal e anual. A sazonalidade semanal é determinada por um índice correspondente a cada dia da semana, enquanto a anual é dada por um dos 53 índices congruentes a cada semana do ano. A Figura 3 do Anexo D mostra um exemplo do *baseline* obtido, face às vendas reais. O gráfico utilizado no simulador para a visualização do *baseline* no período da campanha é apresentado na Figura 4 do Anexo D.

#### 4.4.3 Ferramenta de acompanhamento

Foi desenvolvida uma ferramenta de acompanhamento, que se baseia nos princípios do simulador de impactos. Seleccionados os artigos, lojas e período de acompanhamento, a margem resultante da campanha é comparada com um cenário teórico sem campanha. Utiliza-se a mesma estrutura da folha de cálculo do simulador de campanhas. Assume-se uma margem bruta igual à das três semanas anteriores à campanha.

Esta ferramenta disponibiliza graficamente os principais resultados da campanha, em comparação com um cenário sem campanha (Figura 1 do Anexo E). A pertinência da ferramenta resulta do acompanhamento específico ao artigo e lojas da campanha e a facilidade de obtenção de um *baseline*. Para além da comparação com um cenário sem campanha, pode ser definido pelo utilizador um período homólogo, comparável, para complementar a análise.

## 5 Resultados e discussão

No presente capítulo apresentam-se os principais resultados obtidos, assim como a discussão dos mesmos. Inicia-se pela exposição das conclusões retiradas a partir da análise de fatores. Posteriormente, apresenta-se o desempenho obtido pela previsão através das técnicas de regressão linear múltipla e árvores de regressão. Os resultados insatisfatórios obtidos levaram à estimação do impacto através de intervalos de confiança. Os intervalos construídos proporcionam uma alternativa à previsão do aumento de vendas. Esta técnica permite aferir o nível estimado do impacto consoante uma série de fatores, incluindo uma medida da sua variabilidade. Assim, o processo de desenvolvimento de campanhas futuras terá uma base que permite, de antemão, prever os seus resultados e adequar da melhor maneira a sua parametrização. Por fim, explora-se a incerteza associada ao cálculo do *baseline* e as suas implicações na fiabilidade dos dados obtidos.

### 5.1 Análise estatística

O cálculo do impacto para cada registo da base de dados de campanhas históricas permitiu desenvolver uma análise estatística ao efeito de alguns fatores envolvidos no processo de campanhas no aumento de vendas. O Anexo F apresenta alguns dos resultados da análise efetuada e ainda complementos aos evidenciados no corpo principal da dissertação.

Na análise de variância, a combinação de vários fatores torna a interpretação dos resultados muito complexa, devido à multiplicidade de interações existentes entre os diferentes fatores. Além disso, a adição de cada fator adicional ao modelo requer um aumento exponencial da dimensão das amostras. Como apenas foram tidas em conta amostras de dimensão igual ou superior a 30, para cada combinação possível, não foi possível incorporar na análise um elevado número de fatores, simultaneamente.

#### 5.1.1 Desconto percentual e tipo de marca

A ênfase da análise foi dada a dois fatores: o desconto percentual emitido e o tipo de marca. O tipo de marca é dividido em marca de fornecedor e marca própria. Sempre que o número de registos o permitiu, ambos os fatores foram analisados em conjunto.

Efetuuou-se uma primeira análise de variância a todas as campanhas de desconto em cartão. Na Figura 1 do Anexo F, estão representados os principais resultados do estudo efetuado. Primeiramente, realizou-se um teste à homoscedasticidade dos erros resultantes do modelo, resultando na rejeição dessa hipótese. É de salientar que a análise efetuada utilizou o método de Welch, pelo que a verificação da condição de variância constante não é necessária. O gráfico de dispersão de erros parece evidenciar a independência dos resíduos. Para as restantes análises, a verificação das condições apresentou resultados idênticos.

Analisando a tabela ANOVA, os efeitos dos dois fatores e a interação entre eles apresentaram-se estatisticamente significativos, considerando um nível de significância de 5% (o valor de prova é menor que o nível de significância). Observando a interação entre os efeitos, verificou-se que o impacto médio estimado de campanhas com desconto de 20% é

superior a campanhas com desconto de 25%. Logicamente, um maior desconto deveria apresentar um maior aumento de vendas, como é representado pelos descontos de 30 e 50%. Dado que poderão existir diversos fatores que causam efeitos significativos no impacto de campanhas, não se pode admitir à partida que a amostra de desconto de 20% é uma observação atípica. A marca de fornecedor apresentou um impacto médio sempre superior à marca própria, independentemente do desconto aplicado.

Uma análise de variância considerando as unidades de negócio como fator evidenciou o seu efeito significativo no impacto (Figura 8). Foi conduzida uma análise separada a cada unidade de negócio, tendo em conta o desconto e tipo de marca. Apresentam-se de seguida os principais resultados do estudo.

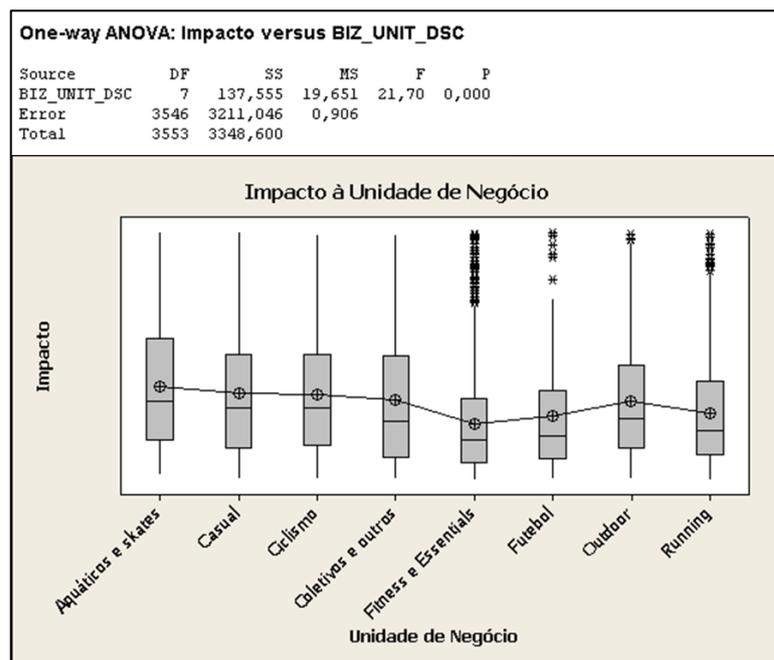


Figura 8 - Efeito da unidade de negócio no impacto promocional

Para a unidade de negócio de Fitness e Essenciais, verificou-se novamente que o impacto médio para campanhas de desconto de 20% era superior ao de 25%. A análise efetuada à unidade de negócio não incluiu esse desconto. O tipo de marca e desconto aplicado mostraram-se significativos. O gráfico da interação entre os efeitos parece demonstrar uma maior diferença de impactos entre os tipos de marca, quando os descontos são maiores (Figura 9). Apesar disso, a interação não é estatisticamente significativa (Figura 2 do Anexo F).

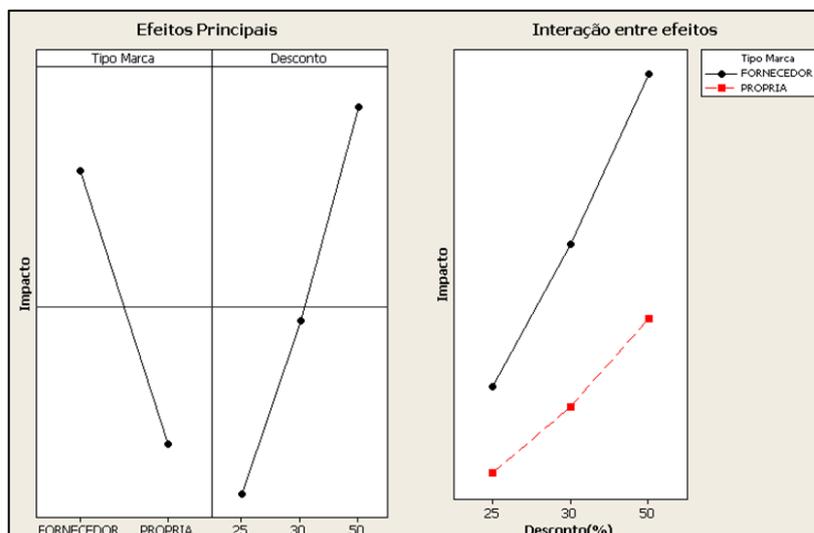


Figura 9 - Efeitos do tipo de marca e desconto na unidade de negócio de Fitness e Essenciais

A análise à unidade de negócio de Casual apresentou resultados semelhantes aos anteriores. Destaca-se, neste caso específico, o facto de que o impacto estimado para descontos de 30% ser significativamente superior aos de 25% e apenas ligeiramente inferior a 50% (Figura 10). O aumento elevado do impacto causado por campanhas com desconto de 30% é pouco credível.

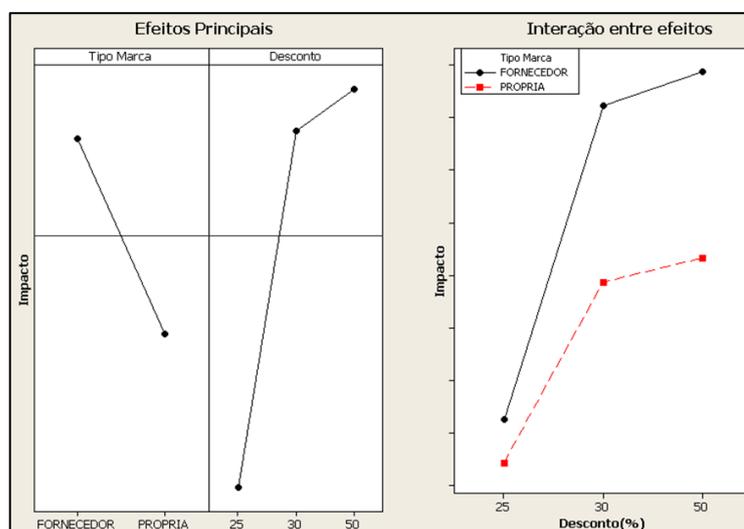


Figura 10 - Efeitos do tipo de marca e desconto na unidade de negócio de Casual

Foi também possível efetuar a comparação entre Casual e Fitness e Essentials, utilizando uma análise de variância com três fatores. Apenas o efeito dos três fatores é significativo (Figura 4 do Anexo F). Nenhuma das interações entre os efeitos apresenta diferenças estatisticamente significativas. No entanto, a diferença do impacto entre tipos de marca aparenta ser maior para descontos superiores. Quanto às unidades de negócio, Casual apresenta melhores resultados que Fitness e Essentials. Salienta-se o facto de que a análise a três fatores já inclui o estudo de quatro interações diferentes, aumentando de modo significativo a sua complexidade.

Destaca-se ainda a unidade de negócio de Ciclismo. Foi efetuado um teste de hipóteses à diferença entre os impactos causados por descontos de 20 e 30% (Figura 11). A diferença é estatisticamente significativa. Contudo, nesta unidade de negócio, tanto o desconto de 20 como o de 30% apresentaram impactos elevados, comparando com as restantes unidades. Este resultado parece indicar que o valor absoluto de desconto emitido poderá ser um fator significativo, já que o preço médio em ciclismo é mais elevado.

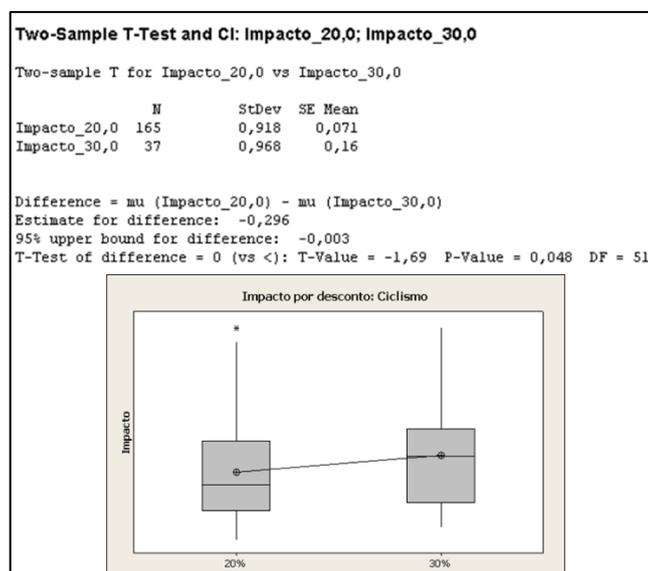


Figura 11 - Efeito do fator desconto na unidade de negócio de ciclismo

Em suma, os resultados gerais da análise às unidades de negócio evidenciaram que a marca de fornecedor é sujeita a maiores impactos em comparação com a marca própria. O efeito do desconto mostrou-se igualmente significativo. Poderá existir uma interação entre o tipo de marca e o desconto, em que maiores descontos resultam em maiores diferenças entre os tipos de marca. O comportamento do desconto e tipo de marca difere para cada unidade de negócio. Por último, conclui-se que os impactos elevados em ciclismo poderão estar relacionados com o valor absoluto de desconto aplicado.

Cada unidade de negócio apresenta um número de artigos elevado, com diferentes tipologias e géneros, por exemplo. A análise a este nível de detalhe dificilmente explicará a variação no impacto causada pela estrutura mercadológica. Por esta razão, estudaram-se os efeitos do tipo de marca e desconto para as categorias da unidade de negócio de Fitness e Essentials. A análise de variância efetuada às categorias evidencia a existência de diferenças significativas (Figura 12).

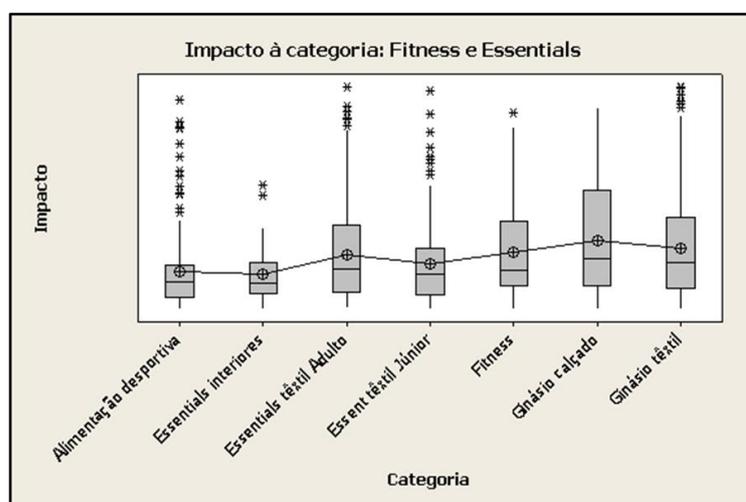


Figura 12 - Efeito da categoria no impacto promocional

A análise de variância ao tipo de marca e desconto para a categoria Essentials Têxtil Júnior evidenciou que apenas o efeito do tipo de marca é significativo (Figura 6 do Anexo F). O facto de só serem utilizados dois níveis de descontos não permite tirar conclusões relevantes sobre a interação entre os fatores (Figura 13). A partir da Figura 12, verificou-se que Essentials Têxtil Júnior apresenta menores impactos que a categoria Essentials Têxtil Adulto. Já que as categorias apresentam a mesma tipologia de artigos, a diferença constatada conduziu a uma análise ao efeito do género no impacto.

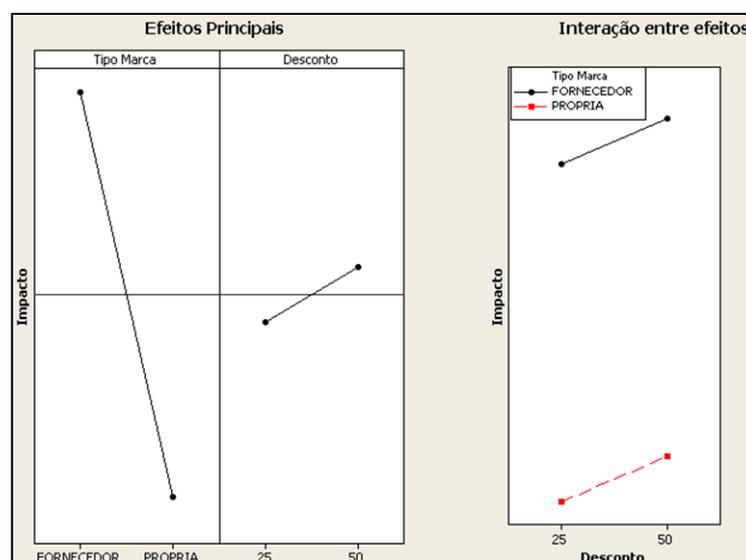


Figura 13 - Efeitos do tipo de marca e desconto na categoria de Essentials Têxtil Júnior

Verificou-se, da mesma forma, uma diferença entre as categorias Ginásio Calçado e Ginásio Têxtil. Apesar de não ser estatisticamente significativa, uma análise ao efeito da tipologia dos artigos permitirá tirar maiores conclusões. Na secção 5.1.2 estudam-se os efeitos da tipologia e género no impacto promocional.

### 5.1.2 Tipologia e género

Nesta secção analisam-se os efeitos da tipologia e género dos artigos no aumento de vendas de uma campanha. Dado que o desconto e o tipo de marca se mostraram, no geral, significativos, as análises seguintes deveriam contemplar ambos. Devido ao número de registos existente, não foi possível integrar simultaneamente os dois fatores na maior parte das análises efetuadas.

Para cada unidade base, foi determinada a sua tipologia e género. Dividiram-se as tipologias em calçado, têxtil, bicicletas, nutrição e equipamentos. Os géneros contemplados foram homem, mulher, unissexo e júnior. Júnior engloba rapaz e rapariga, crianças e bebés.

Conduzindo uma análise de variância à tipologia de artigos, verificou-se apenas uma diferença significativa na tipologia de nutrição, face às restantes (Figura 14). Uma das razões para esta tipologia apresentar impactos mais reduzidos é o uso de descontos percentuais mais baixos. Estudou-se cada tipologia em separado, tendo em conta o género, tipo de marca e desconto.

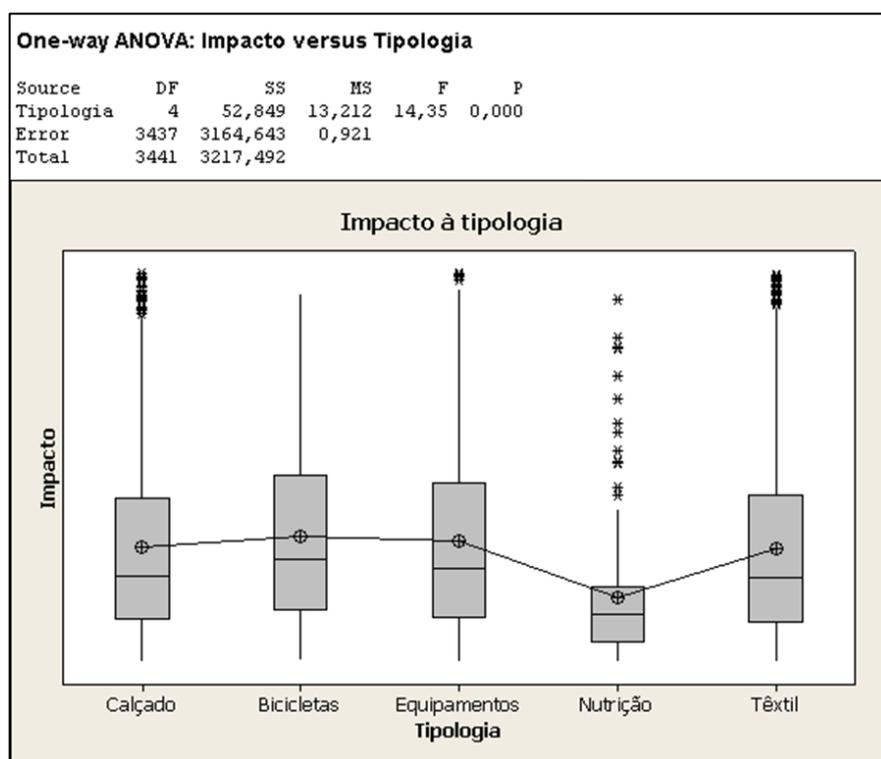


Figura 14 - Efeito da tipologia no impacto promocional

Incorporando os fatores desconto e género no impacto da tipologia de calçado, verificou-se que apenas o desconto tem um efeito estatisticamente significativo (Figura 7 do Anexo F). Contudo, o género de homem parece destacar-se dos restantes.

A tipologia de bicicletas apresentou um comportamento idêntico à unidade de negócio de ciclismo, como seria de esperar. O impacto global é elevado e os descontos percentuais reduzidos. Analisando o efeito dos diferentes géneros para um desconto específico de 20%, não existem diferenças significativas, embora a gama de homem aparente destacar-se de júnior e unissexo (Figura 8 do Anexo F).

Não foi possível retirar conclusões relevantes para a tipologia de equipamentos. Uma divisão dos equipamentos em mais tipologias poderá fazer sentido, visto que a tipologia de equipamentos apresenta uma grande variedade de artigos, como acessórios e máquinas, por exemplo.

Na análise à tipologia de têxtil, foi possível integrar os efeitos do género, tipo de marca e desconto. Os três fatores apresentaram-se estatisticamente significativos (Figura 9 do Anexo F). Em relação ao género, a gama júnior destacou-se pela negativa, comparando com homem e mulher, que não apresentaram diferenças significativas entre ambos. Para a unidade de negócio de Fitness e Essentials, estudaram-se os efeitos do género e tipo de marca na tipologia de têxtil. Apesar de apenas o tipo de marca apresentar diferenças estatisticamente significativas, os impactos inferiores correspondem ao género júnior, enquanto mulher apresenta impactos ligeiramente superiores a homem (Figura 15).

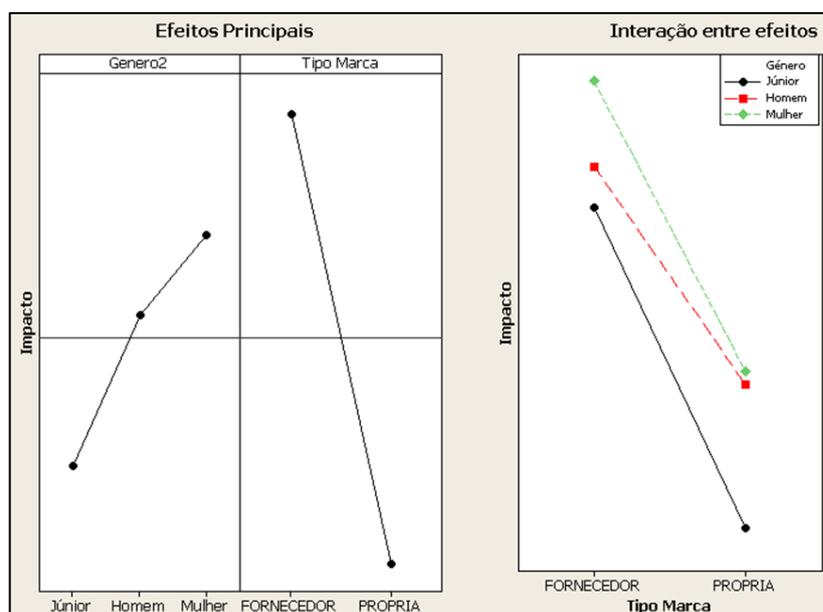


Figura 15 - Efeitos do género e tipo de marca em têxtil na unidade de negócio de Fitness e Essentials

Concluindo, a tipologia de nutrição apresenta impactos significativamente inferiores às restantes. As bicicletas apresentam impactos superiores, quando comparados os descontos percentuais emitidos. O género, no geral, não apresentou diferenças estatisticamente significativas, à exceção da análise à tipologia de têxtil. Contudo, detetou-se que a gama júnior apresenta constantemente impactos inferiores aos géneros de adulto. A diferença entre os géneros de homem e mulher parece variar de acordo com a tipologia de artigos e unidades de negócio.

## 5.2 Regressão linear múltipla e árvore de regressão

Utilizaram-se as técnicas de regressão múltipla e árvores de regressão para o desenvolvimento de modelos de previsão do impacto. Foi definida uma nova estrutura mercadológica, de modo a que o número de registos existentes para cada estrutura fosse superior a 100. Para cada estrutura obtida, foram aplicadas ambas as técnicas. Os dados foram repartidos em dados de treino, constituindo 70% do total de registos, e dados de teste, para os restantes. Empregaram-se os dados de treino para a construção dos modelos, enquanto os dados de teste foram utilizados para avaliar o desempenho dos modelos produzidos.

Na Tabela 1 são apresentados os principais resultados das técnicas. Utilizam-se, como medidas de desempenho, o coeficiente de determinação ( $R^2$ ) ajustado, o erro absoluto médio (MAD) e o erro quadrático médio (MSE). Comparando as duas técnicas, verifica-se que as

árvores de regressão permitiram obter um coeficiente de determinação mais elevado. Contudo, tanto o MAD como o MSE apresentaram-se semelhantes nas duas técnicas.

Tabela 1 - Exemplos de resultados obtidos com regressão múltipla e árvore de regressão

Estrutura	Regressão Múltipla			Árvore de Regressão		
	R <sup>2</sup> ajustado	MAD	MSE	R <sup>2</sup> ajustado	MAD	MSE
<b>Futebol</b>	17.9%	56.8%	55.9%	16.8%	62.9%	70.4%
<b>Coletivos e Outros: Ténis</b>	15.6%	56.7%	49.6%	13.7%	68.8%	80.6%
<b>Coletivos e Outros: restantes</b>	18.0%	67.7%	80.3%	16.9%	71.7%	81.4%
<b>Fitness e Essentials: Ginásio Têxtil: Mulher</b>	17.4%	69.2%	69.3%	30.2%	80.5%	87.2%
<b>Fitness e Essentials: Essentials Têxtil Adulto: Homem</b>	5.1%	59.1%	63.3%	22.5%	61.9%	60.7%
<b>Fitness e Essentials: Essentials Têxtil Júnior</b>	10.4%	55.0%	46.7%	26.0%	60.5%	60.5%
<b>Fitness e Essentials: Alimentação Desportiva</b>	16.5%	43.1%	41.2%	19.2%	42.2%	46.1%
<b>Fitness e Essentials: Restantes</b>	9.2%	76.8%	104.0%	36.8%	76.1%	109.3%
<b>Running: Corrida Calçado</b>	10.7%	72.4%	77.6%	40.6%	62.8%	81.2%

O desempenho obtido não foi considerado como satisfatório para as necessidades de previsão da empresa. Além disso, no caso específico da regressão múltipla, as condições impostas aos erros, idênticas à análise de variância, não foram verificadas. A disposição dos erros não seguiu uma distribuição Normal e a homoscedasticidade não foi verificada (Figura 1 do Anexo G).

Com os fatores utilizados, o R<sup>2</sup> máximo registado foi de cerca de 40%, o que indica que a maior parte da variação do impacto não foi explicada com os modelos. Este resultado foi obtido devido à combinação de duas causas: a não inclusão de fatores com efeitos significativos no impacto e a variabilidade dos dados utilizados. A averiguação de qual das componentes terá maior peso seria pertinente. A variabilidade dos dados utilizados será abordada na secção 5.4 com maior detalhe.

### 5.3 Intervalos de confiança

Foi possível construir uma tabela de impactos, contendo 114 intervalos de confiança (Figura 16). Os intervalos foram computados apenas para combinações resultantes dos fatores analisados: tipo de marca, desconto, tipologia, género, unidade de negócio e categoria. Só as categorias da unidade de negócio de Fitness e Essentials foram analisadas. A combinação de mais ou menos fatores teve em conta o número de registos presentes na base de dados. Para a unidade de negócio de Casual, por exemplo, foram utilizadas combinações entre tipo de marca e desconto. Por outro lado, apenas foi possível calcular o impacto médio de toda a unidade de negócio de Aquáticos e Skates.

Unidade de Negócio	Categoria	Tipo de Marca	Tipologia	Género	Desconto (%)	Limite inferior	Valor Esperado	Limite superior
22 - Coletivos e Outros						30	79%	94%
23 - Fitness		Marca Própria				25	57%	88%
23 - Fitness		Marca Própria				30	36%	64%
23 - Fitness		Marca Própria				50	22%	77%
24 - Running						20	79%	98%
24 - Running						30	45%	70%
24 - Running		Marca Própria				20	65%	97%
24 - Running		Marca Própria				30	47%	55%
24 - Running		Marca Própria				40	10%	14%
24 - Running		Fornecedor				20	46%	84%
25 - Aquáticos e Skates							69%	91%
26 - Casual						25	8%	77%
26 - Casual						50	62%	100%
26 - Casual		Marca Própria				30	41%	57%
26 - Casual		Fornecedor				50	14%	20%
27 - Outdoor		Fornecedor				25	12%	94%
27 - Outdoor		Fornecedor				30	22%	60%
27 - Outdoor		Fornecedor				50	63%	83%
		Fornecedor	Nutrição				25%	37%
		Fornecedor	Calçado	Júnior		30	59%	94%
		Fornecedor	Calçado	Homem		30	73%	89%
		Fornecedor	Calçado	Mulher		25	37%	64%
		Fornecedor	Calçado	Mulher		30	49%	59%
		Fornecedor	Calçado	Mulher		50	26%	64%
		Marca Própria	Têxtil	Júnior		25	91%	100%
		Marca Própria	Têxtil	Júnior		50	2%	65%
		Marca Própria	Têxtil	Homem		30	34%	46%

Figura 16 - Exemplo retirado da tabela de impactos desenvolvida

A amplitude dos intervalos de confiança está relacionada com a dimensão existente de registos e o seu desvio padrão, que constitui uma medida da variabilidade das amostras. A Figura 17 apresenta um histograma das amplitudes dos intervalos de confiança obtidos.

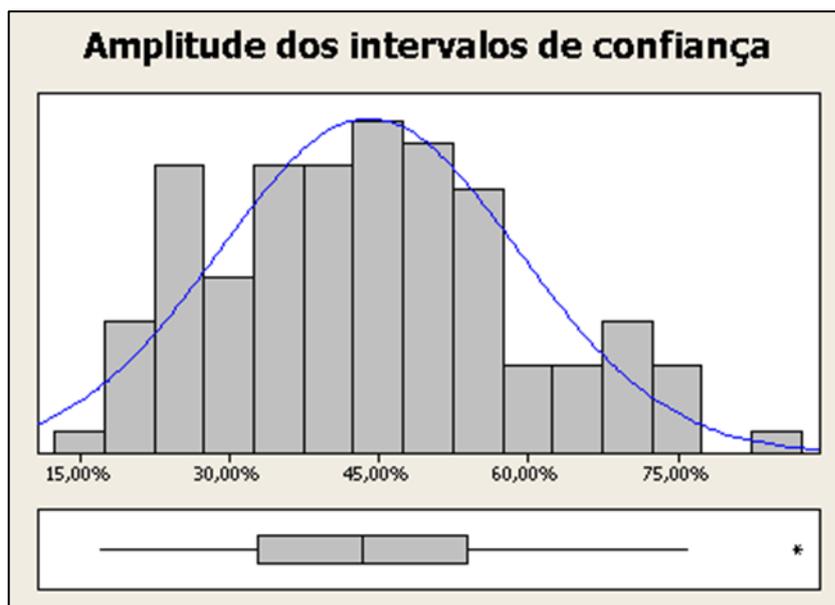


Figura 17 - Histograma e *boxplot* das amplitudes dos intervalos de confiança obtidos

A amplitude mínima obtida para os intervalos de confiança foi de 17%, sendo que a máxima atingiu 87%. A distribuição das amplitudes demonstra uma forma Normal, concentrando-se a maior parte entre 30 e 50%. A obtenção de um maior número de registos permitirá diminuir consideravelmente a amplitude dos intervalos obtidos. A alta variabilidade dos impactos registados poderá estar relacionada com os erros provenientes do modelo de previsão do *baseline*. Na secção 5.4 é detalhada a problemática resultante do seu cálculo.

#### 5.4 Erro na determinação do *baseline*

Visto que a determinação do *baseline* parte de um modelo de previsão, existirá necessariamente um erro associado ao seu cálculo. Assim sendo, a avaliação da incerteza

associada à metodologia definida torna-se pertinente. Adicionalmente, dado que o *baseline* é utilizado no cálculo do aumento de vendas, o erro associado ao impacto será ainda maior.

A título de exemplo, consideremos um caso teórico em que uma determinada campanha apresenta vendas líquidas de 100€, quando, num cenário sem campanha, obteria apenas 50€. O seu impacto, de acordo com a fórmula utilizada, seria de 100%. Na prática, não tendo acesso às vendas do cenário sem campanha, determina-se um *baseline* de 40€, a partir do modelo definido. O erro relativo associado ao modelo é apenas de 20%. Porém, de acordo com o *baseline*, o impacto calculado é de 150%. Ou seja, um erro de 20% na previsão do *baseline* resultou num erro de 50% na determinação do impacto.

Para a avaliação da incerteza, seria necessária a criação de um período de teste, isento de efeitos promocionais e outros efeitos externos relevantes. A multiplicidade de campanhas existentes e a alta sazonalidade dos artigos tornam este processo mais complexo. O nível de agregação definido tem uma contribuição importante na redução do erro associado ao modelo. Apesar disso, a diferença de dimensões dos registos extraídos é evidente. A base de dados utilizada para a análise contém registos com vendas na ordem dos 20€ até aos 200.000€. É expectável que, para registos de menor dimensão, o erro médio envolvido seja superior.

## 6 Conclusões e perspectivas de trabalho futuro

A presente dissertação aborda o desenvolvimento de uma nova metodologia para a análise e previsão do impacto de campanhas de um retalhista especializado. Anualmente, a empresa realiza diversas ações promocionais de diferentes carizes. As campanhas efetuadas contêm uma variedade alargada de especificações. A oferta promocional compreende por inteiro o seu universo de lojas e artigos, abrangendo todos os níveis da sua estrutura mercadológica. De modo adicional, a característica sazonal dos seus artigos não permite a análise a este nível de detalhe.

Anteriormente ao projeto, a análise de campanhas era realizada a partir da comparação de vendas e margens entre o período promocional e um período homólogo, comparável. Apenas as grandes campanhas eram alvo de uma análise mais detalhada, comparando a sua prestação com a mesma do ano anterior. O confronto com outras campanhas apresenta várias desvantagens. Variando o horizonte do calendário promocional, por exemplo, é necessário um processo de extrapolação. A alta sazonalidade dos artigos impede que o conjunto de artigos em campanha permaneça igual de um ano para o outro, sendo que o mesmo é verificado para as lojas.

Propõe-se neste estudo uma abordagem inovadora à análise do desempenho promocional do retalhista. A metodologia desenvolvida permite o cálculo uniforme do impacto da generalidade das campanhas, independentemente das suas dimensões. O seu impacto é determinado pela comparação do desempenho real de uma promoção com um cenário teórico sem campanha. A avaliação generalizada das ações promocionais permite não só uma análise mais detalhada aos fatores que influenciam significativamente o seu impacto, como a estimação de impactos futuros, consoante esses fatores. Estas duas componentes têm como objetivo o auxílio ao processo de decisão no desenho de campanhas futuras, já que permitem prever os seus resultados e adaptar da melhor forma os fatores que as caracterizam.

O projeto foi repartido em três grandes objetivos. O seu principal propósito é a simulação de impactos de campanhas futuras, de acordo com as suas características. Para esse efeito, foi necessária a determinação prévia dos impactos das campanhas históricas, para que seja possível a extrapolação para os desempenhos futuros. A abordagem definida para o cálculo dos impactos históricos tem como último objetivo a sua utilização para o acompanhamento de campanhas a decorrer.

O apuramento dos impactos históricos apresenta duas fases: o levantamento das campanhas históricas e o posterior cálculo do seu impacto. Foi definido um horizonte temporal de 2 anos de histórico. O nível de agregação utilizado na base de dados de campanhas históricas compreende a combinação de cada campanha, mecânica promocional, unidade base e marca. O impacto, calculado para cada combinação, é dado pela diferença relativa entre as vendas líquidas reais e um *baseline*. O *baseline* corresponde às vendas realizadas caso a campanha não existisse. A sua determinação parte de um modelo de previsão baseado nas vendas das três semanas anteriores ao início da campanha. O modelo baseia-se numa componente semanal, dada pela média móvel das vendas semanais, adicionando-lhe um índice constante para cada dia da semana que não esteja numa semana completa.

Após a construção da base de dados e posterior cálculo do impacto, analisaram-se alguns dos fatores que poderão causar variações significativas no mesmo. As principais variáveis consideradas foram a quantidade de desconto, o tipo de marca, a tipologia e o género. Utilizou-se a técnica de análise de variância para inferir diferenças significativas. De seguida, foram desenvolvidos modelos de previsão para a simulação de novos impactos, utilizando as técnicas de regressão múltipla e árvores de regressão. Dado que as duas técnicas empregadas não apresentaram resultados satisfatórios, recorreu-se à estimação de intervalos de confiança para o valor esperado do impacto, combinando os fatores previamente analisados.

Foram construídas duas ferramentas para o auxílio da construção de novas campanhas e do acompanhamento de campanhas a decorrer. O simulador de campanhas futuras permite, a partir da análise realizada e impactos estimados, aferir o aumento de vendas esperado para a campanha e comparar a margem efetuada entre um cenário com campanha e um sem ações promocionais. A ferramenta de acompanhamento utiliza a metodologia definida para o *baseline* para efetuar a comparação entre as vendas reais e as que seriam expectáveis caso a campanha não existisse.

## 6.1 Principais resultados

A análise estatística às unidades de negócio demonstrou que tanto o tipo de marca como o desconto causam variações significativas no impacto. As marcas de fornecedor apresentam impactos superiores às marcas próprias. Poderá também existir uma interação entre os dois fatores, em que, para descontos superiores, a diferença entre tipos de marca é mais evidente. Contudo, o comportamento dos dois fatores varia de acordo com a unidade de negócio. Os resultados elevados apresentados em ciclismo, com descontos percentuais reduzidos, indicam que o valor absoluto do desconto poderá também ser um fator significativo.

Num estudo mais detalhado, ao nível da categoria, identificaram-se os fatores tipologia e género como possíveis variáveis significativas. Dividiram-se as tipologias em têxtil, calçado, equipamentos, nutrição e bicicletas. Os géneros foram repartidos em homem, mulher e júnior. A tipologia nutrição apresentou impactos significativamente inferiores, em comparação com as restantes. As bicicletas mostraram impactos superiores, quando comparados os descontos percentuais emitidos. O efeito do género foi estudado para cada tipologia. No geral, não foram identificados efeitos estatisticamente significativos, à exceção da tipologia de têxtil, em que júnior se destacou pela negativa face aos géneros de adulto. Este comportamento mantém-se para as restantes tipologias. Os efeitos dos géneros de homem e mulher apresentam comportamentos distintos entre unidades de negócio e tipologias.

As técnicas de regressão múltipla e árvores de regressão utilizadas no desenvolvimento de modelos de previsão para o impacto, não apresentaram resultados suficientemente positivos para as necessidades requeridas. Ambas apresentaram desempenhos semelhantes. No caso da regressão múltipla, as condições de normalidade e variância constante dos erros não foram verificados. O coeficiente de determinação máximo obtido foi de 40%. O facto de grande parte da variação não ser explicada por ambos os modelos poderá resultar tanto da falta de envolvimento de fatores com efeitos relevantes no impacto como da variabilidade dos dados utilizados.

Construiu-se uma tabela de impactos, em que, para diferentes combinações entre os fatores previamente analisados, os impactos foram estimados através de intervalos de confiança. As amplitudes dos 114 intervalos obtidos concentram-se entre os 30 e 50%. A obtenção de um maior número de registos permitirá diminuir a amplitude dos intervalos.

## 6.2 Limitações e perspectivas de trabalho futuro

O impacto foi determinado apenas para os artigos, lojas e período em campanha. Uma análise que contemple diferentes produtos e períodos posteriores permitiria, por exemplo, o estudo de efeitos promocionais relevantes, como o *stockpiling*, contágios ou canibalizações. Os estudos realizados indicam que estes efeitos apresentam um peso significativo no impacto de campanhas. A inclusão de novas métricas, como a cesta média e o número de transações, permitiriam avaliar o impacto promocional de diferentes perspectivas. A interação entre campanhas a decorrer em simultâneo também não foi considerada.

Para trabalhos futuros poderá fazer sentido incorporar outras variáveis que podem explicar o impacto, tais como: o desconto absoluto emitido, informação sobre lojas ou o tipo de comunicação efetuada.

A análise estatística realizada constituiu apenas um ponto de partida. A determinação dos impactos de campanhas históricas permitiu construir uma base de dados que possibilita a análise de diferentes fatores. Foi construída uma interface com o objetivo de auxiliar a análise de novos fatores e construir intervalos de confiança adicionais. Dado o processo demoroso que envolve a extração de dados, a base construída serviu para fornecer dados para o âmbito do projeto. A metodologia desenvolvida para o cálculo do *baseline* permitirá aumentar a extensão da base de dados para outro tipo de campanhas, por exemplo, o que possibilitará alargar o potencial de estudo.

## Referências

- Ailawadi, Kusum, Bari A. Harlam, Jacques César, and David Trounce. 2006. "Promotion Profitability for a Retailer: The Role of Promotion, Brand, Category, and Store Characteristics." *Journal of Marketing Research* 43:518-535.
- Ali, Özden Gür, Serpil Sayın, Tom van Woensel, and Jan Fransoo. 2009. "SKU demand forecasting in the presence of promotions." *Expert Systems with Applications* 36 (10):12340-12348.
- Bell, David R., Jeongwen Chiang, and V. Padmanabhan. 1999. "The Decomposition of Promotional Response: An Empirical Generalization." *Marketing Science* 18 (4):504-526.
- Box, George E. P., and Norman Richard Draper. 1987. *Empirical model-building and response surfaces*. Vol. 424: Wiley New York.
- Box, George E. P., and G. Jenkins. 1970. *Time Series Analysis, Forecasting and Control*. San Francisco: Holden-Day.
- Buntine, Wray. 1992. "Learning classification trees." *Statistics and Computing* 2 (2):63-73.
- Chambers, John C., Satinder K. Mullick, and Donald D. Smith. 1971. "How to Choose the Right Forecasting Technique." *Harvard Business Review* 49:45-71.
- Clemen, Robert T. 1989. "Combining forecasts: A review and annotated bibliography." *International Journal of Forecasting* 5 (4):559-583.
- Cooper, Lee G., Penny Baron, Wayne Levy, and Paris Gogos. 1999. "PromoCast™: A New Forecasting Method for Promotion Planning." *Marketing Science* 18 (3):301-316.
- de Miranda, José Manuel. 2012. "Estudo do impacto das ações promocionais no negócio." Faculdade de Engenharia, Universidade do Porto.
- Divakar, Suresh, Brian T. Ratchford, and Venkatesh Shankar. 2005. "Practice Prize Article—CHAN4CAST: A Multichannel, Multiregion Sales Forecasting Model and Decision Support System for Consumer Packaged Goods." *Marketing Science* 24 (3):334-350.
- Draper, N., and H. Smith. 1981. *Applied Regression Analysis*. New York: John Wiley & Sons.
- Fildes, R., K. Nikolopoulos, S. F. Crone, and A. A. Syntetos. 2008. "Forecasting and operational research: a review." *Journal of the Operational Research Society* 59 (9):1150-1172.
- Fildes, Robert, Paul Goodwin, and Michael Lawrence. 2006. "The design features of forecasting support systems and their effectiveness." *Decision Support Systems* 42 (1):351-361.
- Gardner, Everette S. 2006. "Exponential smoothing: The state of the art—Part II." *International Journal of Forecasting* 22 (4):637-666.

- Gedenk, Karen, Scott A. Neslin, and Kusum L. Ailawadi. 2010. "Sales Promotion." In *Retailing in the 21st Century: Current and Future Trends*, edited by Manfred Krafft and K. Murali Mantrala, 393-407. Berlin, Heidelberg: Springer Berlin Heidelberg.
- Guimarães, Rui Manuel Campos, and José António Sarsfield Cabral. 2011. *Estatística*. 2.<sup>a</sup> ed ed. Lisboa: Verlag Dashöfer.
- Gupta, Sunil. 1988. "Impact of Sales Promotions on When, What, and How Much to Buy." *Journal of Marketing Research* 25 (4):342-355.
- Heerde, Harald J. van , Sachin Gupta, and Dick R. Wittink. 2003. "Is 75% of the Sales Promotion Bump Due to Brand Switching? No, Only 33% Is." *Journal of Marketing Research* 40 (4):481-491.
- Herr, David G. 1986. "On the History of ANOVA in Unbalanced, Factorial Designs: The First 30 Years." *The American Statistician* 40 (4):265-270.
- Hill, Tim, Leorey Marquez, Marcus O'Connor, and William Remus. 1994. "Artificial neural network models for forecasting and decision making." *International Journal of Forecasting* 10 (1):5-15.
- Hodge, Victoria J., and Jim Austin. 2004. "A Survey of Outlier Detection Methodologies." *Artificial Intelligence Review* 22 (2):85-126.
- Huang, Tao, Robert Fildes, and Didier Soopramanien. 2014. "The value of competitive information in forecasting FMCG retail product sales and the variable selection problem." *European Journal of Operational Research* 237 (2):738-748.
- Kalwani, Manohar U., and Chi Kin Yim. 1992. "Consumer Price and Promotion Expectations: An Experimental Study." *Journal of Marketing Research* 29 (1):90-100.
- Keselman, H. J., Carl J. Huberty, Lisa M. Lix, Stephen Olejnik, Robert A. Cribbie, Barbara Donahue, Rhonda K. Kowalchuk, Lauren L. Lowman, Martha D. Petoskey, Joanne C. Keselman, and Joel R. Levin. 1998. "Statistical Practices of Educational Researchers: An Analysis of Their ANOVA, MANOVA, and ANCOVA Analyses." *Review of Educational Research* 68 (3):350-386.
- Lawrence, Michael, Paul Goodwin, Marcus O'Connor, and Dilek Önköl. 2006. "Judgmental forecasting: A review of progress over the last 25 years." *International Journal of Forecasting* 22 (3):493-518.
- Ma, Shaohui, Robert Fildes, and Tao Huang. 2015. "Demand forecasting with high dimensional data: The case of SKU retail sales forecasting with intra- and inter-category promotional information." *European Journal of Operational Research* 249 (1):245-257.
- Makridakis, Spyros, and Michèle Hibon. 2000. "The M3-Competition: results, conclusions and implications." *International Journal of Forecasting* 16 (4):451-476.
- Makridakis, Spyros, Rob J Hyndman, and Steven C Wheelwright. 1998. *Forecasting: Methods and Applications*. 3rd ed. Nova Iorque: John Wiley & Sons.
- Mondom, A. 2013. "Forecast Support Tool For Sales Promotion Campaigns; Design, Implementation and Evaluation." Economics & ICT, Department of Economics and Informatics, Erasmus University.
- Pancras, Joseph, S. Siriam, and V. Kumar. 2012. "Empirical Investigation of Retail Expansion and Cannibalization in a Dynamic Environment." *Management Science* 58 (11):2001-2018.

- Poh, H. L., J. Yao, and T. Jašic. 1998. "Neural networks for the analysis and forecasting of advertising and promotion impact." *International Journal of Intelligent Systems in Accounting, Finance & Manag* 7 (4):253-268.
- Ramanathan, Usha, and Luc Muyltermans. 2010. "Identifying demand factors for promotional planning and forecasting: A case of a soft drink company in the UK." *International Journal of Production Economics* 128 (2):538-545.
- Sousa, João. 2011. "Aplicação de Redes Neurais na Previsão de Vendas para Retalho." Faculdade de Engenharia, Universidade do Porto.
- Trapero, Juan R., Nikolaos Kourentzes, and Robert Fildes. 2015. "On the identification of sales forecasting models in the presence of promotions." *Journal of Operational Research Society* 66 (2):299-307.
- Trapero, Juan R., Diego J. Pedregal, R. Fildes, and N. Kourentzes. 2013. "Analysis of judgmental adjustments in the presence of promotions." *International Journal of Forecasting* 29 (2):234-243.
- Trusov, Michael, Anand V. Bodapati, and Lee G. Cooper. 2006. "Retailer promotion planning: Improving forecast accuracy and interpretability." *Journal of Interactive Marketing* 20 (3-4):71-81.
- Tversky, Amos, and Daniel Kahneman. 1974. "Judgment under Uncertainty: Heuristics and Biases." *Science* 185 (4157):1124-1131.
- van Heerde, Harald J., Peter S. H. Leeflang, and Dick R. Wittink. 2002. "How promotions work: SCAN\*PRO-based evolutionary model building." *Schmalenbach Business Review* 54:198-220.
- Welch, B. L. 1951. "On the Comparison of Several Mean Values: An Alternative Approach." *Biometrika* 38 (3/4):330-336.
- Zotteri, Giulio, Matteo Kalchschmidt, and Federico Caniato. 2005. "The impact of aggregation level on forecasting performance." *International Journal of Production Economics* 93-94:479-491.

## ANEXO A: Categorias da unidade de negócio de Fitness e Essentials

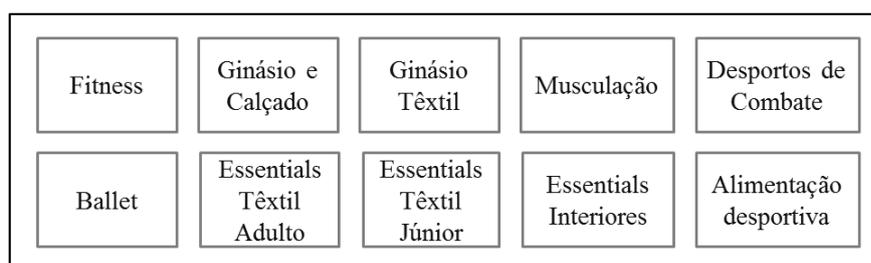


Figura A 1 - Categorias da unidade de negócio de Fitness e Essentials

## ANEXO B: Recolha e filtragem da Base de Dados

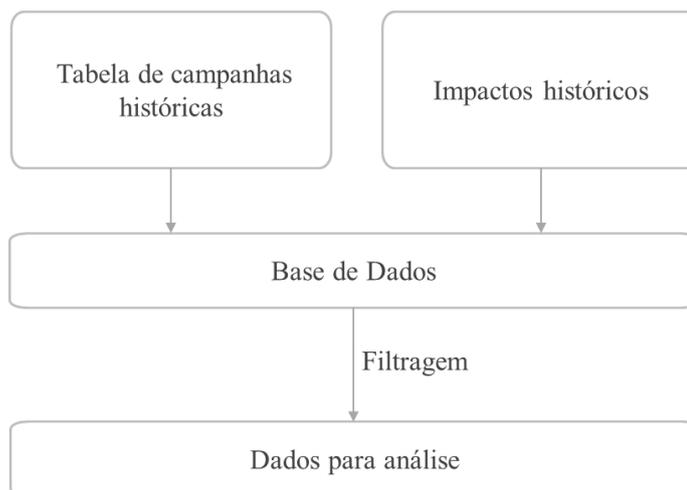


Figura B 1- Processo de recolha e tratamento de dados para a análise

A análise e a previsão de impactos utilizaram dados que passaram por um processo de tratamento. Primeiramente, foi construída uma tabela com todas as campanhas históricas e as suas características. A partir desta tabela, determinou-se o impacto de cada campanha. A conjugação da tabela de campanhas históricas e o seu impacto é designada de base de dados. Os dados utilizados tanto para a análise como para a previsão correspondem a uma pequena porção da base de dados, dado que o objetivo da filtragem foi obter um conjunto de dados robusto e minimizar o número de possíveis *outliers*.

CAMPANHA	Data início	Data fim	UN	CAT	SUBCAT	UB	Marca	MECÂNICA
CALÇADO OUTDOOR	19-11-2014	08-12-2014	Outdoor	Outd casual calçado	Criança	Adventure	BERG	Desconto em Cartão - 50%
CALÇADO OUTDOOR	19-11-2014	08-12-2014	Outdoor	Outd casual calçado	Júnior	Adventure	BERG	Desconto em Cartão - 50%
CALÇADO OUTDOOR	19-11-2014	08-12-2014	Outdoor	Outd casual calçado	Mulher	Street	BERG	Desconto em Cartão - 50%
CALÇADO OUTDOOR	19-11-2014	08-12-2014	Outdoor	Outd casual calçado	Mulher	Adventure	BERG	Desconto em Cartão - 50%
CALÇADO OUTDOOR	19-11-2014	08-12-2014	Outdoor	Outd casual calçado	Homem	Street	BERG	Desconto em Cartão - 50%
TÉNIS_PADEL_BASK_COLET	04-12-2014	25-12-2014	Coletivos e outros	Outros desportos	Outros jogos	Jogos	PANASONIC	Desconto em Cartão - 50%
TÉNIS_PADEL_BASK_COLET	04-12-2014	25-12-2014	Coletivos e outros	Outros desportos	Baseball	Bolas	SPORTZONE	Desconto em Cartão - 50%
TÉNIS_PADEL_BASK_COLET	04-12-2014	25-12-2014	Coletivos e outros	Outros desportos	Dardos	Soft tip	WINMAU	Desconto em Cartão - 50%
TÉNIS_PADEL_BASK_COLET	04-12-2014	25-12-2014	Coletivos e outros	Outros desportos	Voleibol	Calçado	ASICS	Desconto em Cartão - 50%
TÉNIS_PADEL_BASK_COLET	04-12-2014	25-12-2014	Coletivos e outros	Outros desportos	Voleibol	Bolas	SPORTZONE	Desconto em Cartão - 50%

NR_SKUS_PARAM	NR_STYLE_PARAM	NR_LOJAS_PARAM	NR_SKUS_VENDIDOS	NR_STYLE_VENDIDOS	NR_LOJAS_VENDIDOS	Vendas Líquidas	VL Antes de descontos	Baseline	Impacto	Vendas Brutas	Margem Líquida	Quantidade
5	4	73	2	2	50	18211	18211	13042	40%	22400	5084.22	200
10	2	73	10	2	30	7021	7021	1003	600%	8636	10852.85	374
40	28	73	35	20	27	293	293	210	40%	360	4037.15	321
3	1	73	3	1	55	1194	1194	2323	-49%	1469	6942.92	143
20	10	73	18	9	48	62392	62392	50109	25%	76742	11434.47	714
30	15	73	25	13	10	2116	2116	2504	-15%	2603	50.71	93
5	4	73	3	4	50	959	959	1013	-5%	1180	29.38	200
3	2	73	3	2	61	63	63	21	200%	77	221.52	132
24	8	73	20	8	70	3452	3452	2000	73%	4246	2050.73	98
10	3	73	5	3	53	609	609	354	72%	749	420.4	23

Figura B 2 - Estrutura da base de dados de campanhas históricas

A Figura 2 apresenta a estrutura da base de dados construída. Os dados da figura são fictícios. O nível de agregação utilizado constituiu a combinação entre campanha, mecânica promocional, unidade base e marca. Todas as hierarquias da estrutura mercadológica até à unidade base foram registadas. As datas de início e fim de cada campanha também foram consideradas.

Para cada combinação foram recolhidas diversas métricas, assim como calculados o *baseline* e o impacto. *NR\_SKUS\_PARAM* representa o número de artigos filho parametrizados, *NR\_STYLE\_PARAM* o número de artigos pai e *NR\_LOJAS\_PARAM* o número de lojas. Foram também registados os números de artigos e lojas em que existiram vendas no período de campanha. Nas mecânicas promocionais de desconto direto, as vendas líquidas já contêm os descontos aplicados. Para estes casos foram calculadas as vendas líquidas antes de descontos. As vendas brutas, margem líquida e quantidade vendida foram também registados.

## ANEXO C: Análise e previsão de impactos

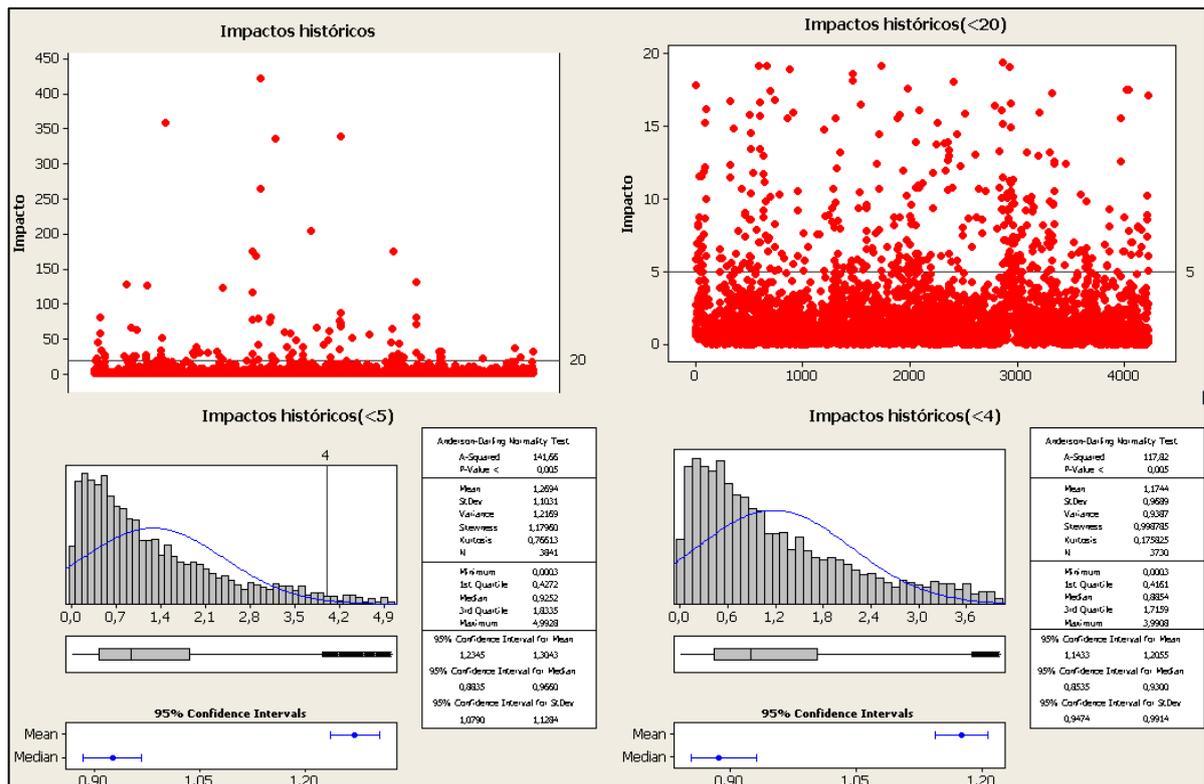


Figura C 1 - Processo de remoção de impactos outliers

O processo de remoção de impactos outliers foi realizado com o auxílio do software Minitab. Inicialmente, construiu-se um gráfico de dispersão com todos os impactos calculados (canto superior esquerdo). Verificaram-se pontos que se encontravam deslocados face à maioria dos impactos, sendo definido um limite superior de 2000%. De seguida, utilizando a mesma abordagem (canto superior direito), foi imposto um limite de 500%. Por fim, foi definido o teto superior de 400%, baseando a decisão num histograma e diagrama de caixa computados pelo Minitab. O software identifica como outliers as observações que se encontram a mais de uma certa distância do final da caixa. A distância é 1,5 vezes o comprimento da caixa, dado pela diferença entre o primeiro e terceiro quartis.

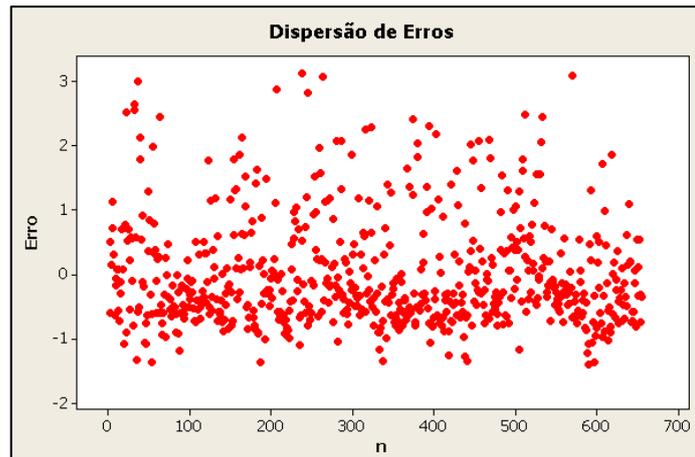


Figura C 2- Exemplo de um gráfico de dispersão de erros provenientes da análise de variância

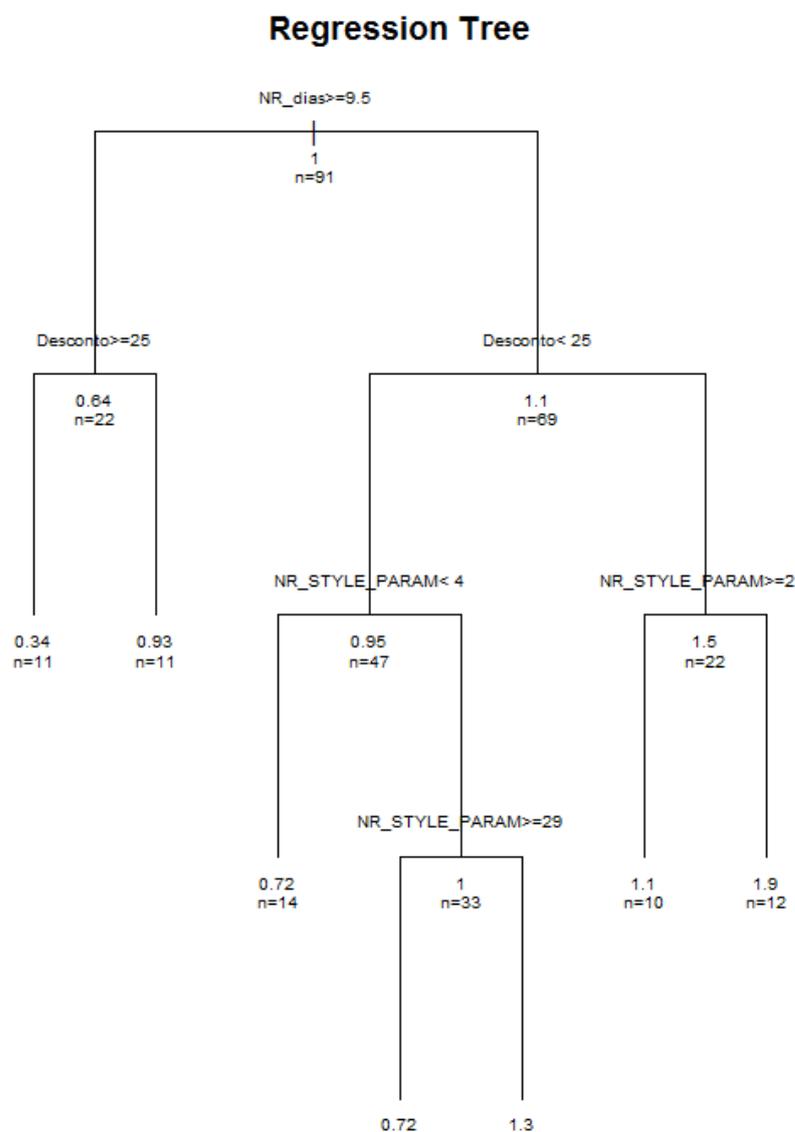


Figura C 3 - Exemplo de um resultado obtido a partir da técnica de árvore de regressão

A Figura 3 apresenta um exemplo de um resultado de uma árvore de regressão, fornecido automaticamente pelo *software R*. A cada nó da árvore uma variável é dividida por ramos que representam os diferentes valores que a variável apresenta. O impacto e o número de observações são registados para cada divisão (ramos), até à extremidade (folhas). Caso a condição do nó seja verdadeira, o impacto esperado será o apresentado no ramo da esquerda.

## ANEXO D: Ferramenta simuladora de impactos

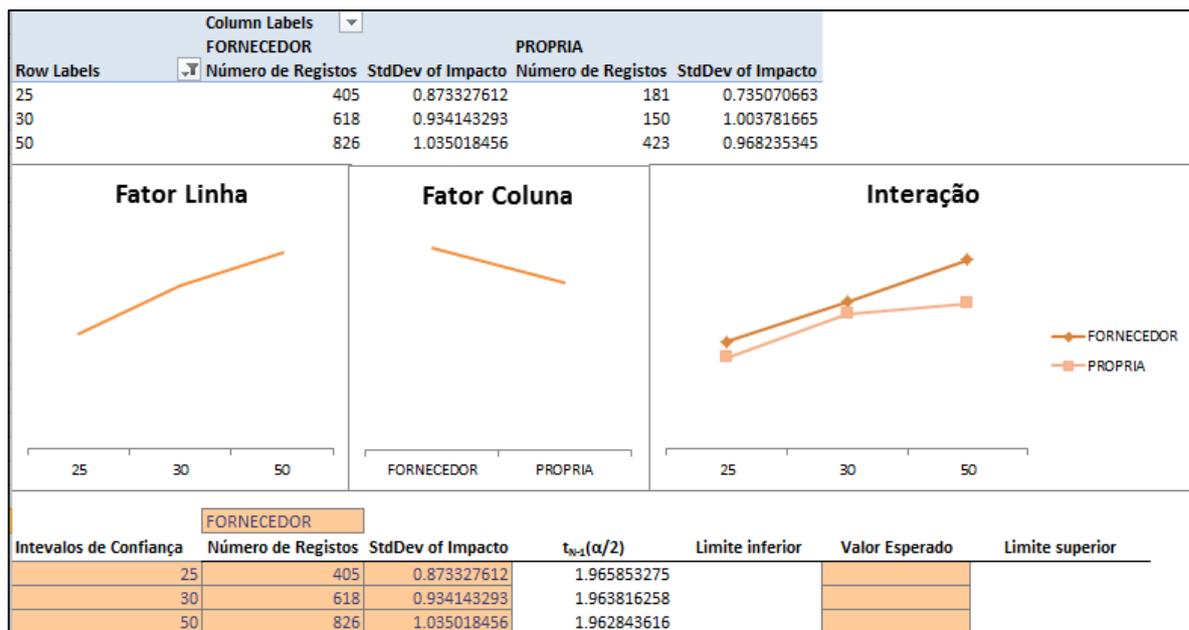
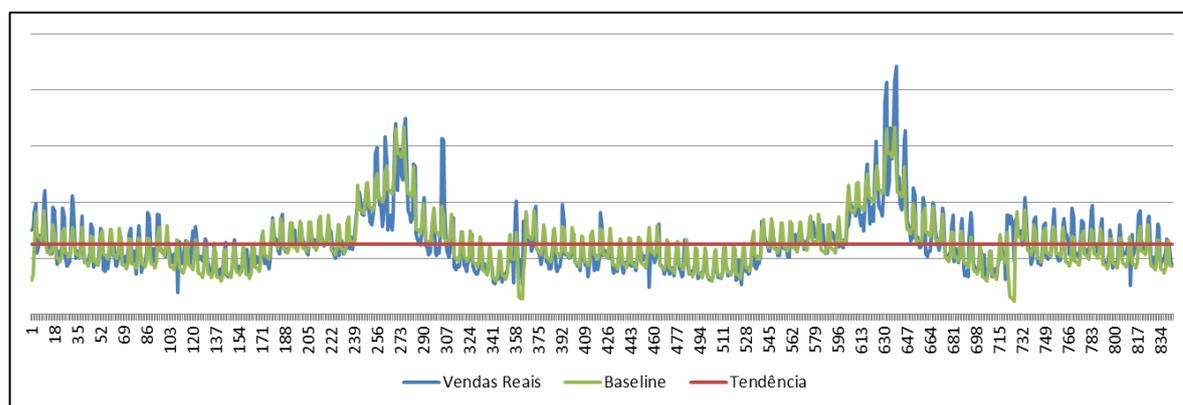
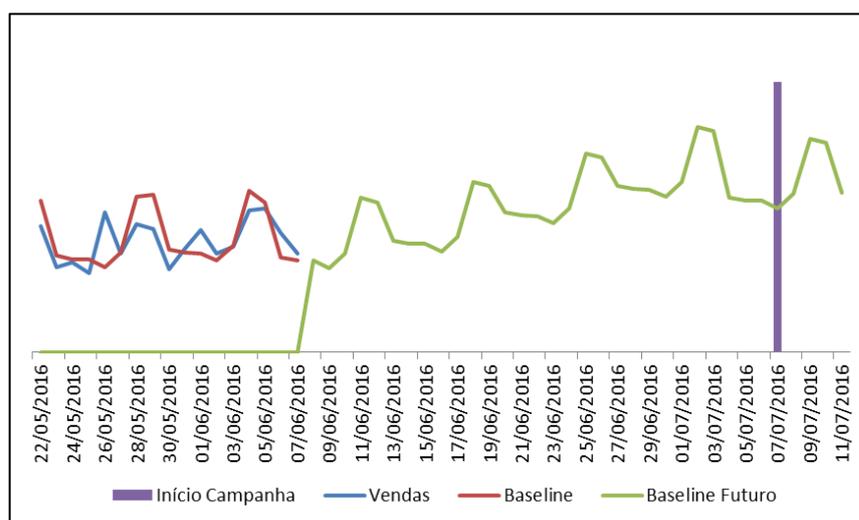


Figura D 1 - Plataforma para o estudo do efeito de diferentes fatores no impacto promocional

Unidade de Negócio/Categoria:	2201 - TÊNIS
<b>Cenário Sem Campanha</b>	
Baseline VL (€)	20.000 €
MFO (%) Baseline	15,0%
MFO (€) Baseline	3.000 €
Custo Mercadorias Vendidas	17.000 €
<b>Cenário Com Campanha</b>	
Crescimento VL (%)	75%
Crescimento (€)	15.000 €
VL Totais (sem descontos)	35.000 €
VB Totais (sem descontos)	43.050 €
MFO (€) (sem descontos)	5.250 €
Custo Mercadorias Vendidas	29.750 €
Desconto (%)	30%
Desconto (€)	12.915 €
Taxa Rebate	100%
Desconto Rebatido	12.915 €
MFO (€) Final	-7.665 €
MFO (%) Final	-21,9%
Impacto direto	-10.665 €
Descontos comerciais	
Receitas comerciais	
Provisões libertadas acrescidas	
Despesas acrescidas de Marketing	
Despesas acrescidas de Logística	
Outras Despesas acrescidas	
<b>Impacto final</b>	<b>-10.665 €</b>

Figura D 2 - Simulador de rentabilidade de campanhas futuras

Figura D 3 - Exemplo do ajuste do *baseline* face às vendas reaisFigura D 4 - Gráfico para o *baseline* utilizado no simulador

O objetivo principal da ferramenta simuladora de campanhas é auxiliar o processo de decisão dos agentes comerciais na definição de novas campanhas. A ferramenta fornece uma base para a determinação do aumento de vendas esperado com uma campanha, tendo em conta a combinação de vários fatores, como o desconto aplicado, a estrutura mercadológica à qual o desconto é aplicado e o tipo de marca dos artigos, por exemplo.

Foi construída uma tabela que contém intervalos de confiança para o valor esperado do aumento de vendas de uma campanha (Figura 16 do corpo principal). Escolhendo a combinação de fatores pretendida, os agentes comerciais definem um impacto esperado para a campanha, tendo em consideração o intervalo de confiança.

O crescimento de vendas esperado é inserido no simulador de rentabilidade (Figura 2), assim como o desconto a ser aplicado e outras receitas ou despesas incrementais que derivam da realização da campanha. O simulador determina se o crescimento de vendas originário da campanha é suficiente para compensar a redução de margem resultante do desconto aplicado e outras despesas comerciais. O resultado final do simulador é positivo se a margem que se espera obter sem campanha for inferior à margem obtida com campanha.

O *baseline* de vendas para o cenário sem campanha é determinado pela ferramenta. É apresentado um gráfico com o *baseline* esperado para o período de campanha e para a janela temporal anterior à campanha (Figura 4). O modelo de previsão usado para o cálculo do *baseline* tem por base um horizonte temporal mais alargado, de pelo menos dois anos, de modo a incorporar o comportamento anual das vendas. O ajuste do *baseline* obtido face às vendas reais é apresentado, a título de exemplo, na Figura 3.

Foi desenvolvida uma plataforma para a análise do efeito de diferentes fatores no impacto promocional (Figura 1). Caso o número de registos seja significativo, podem ser construídos novos intervalos de confiança e posteriormente inseridos na tabela de impactos. Caso a base de dados seja expandida, esta plataforma auxiliará a atualização dos intervalos de confiança.

## ANEXO E: Ferramenta de acompanhamento de campanhas

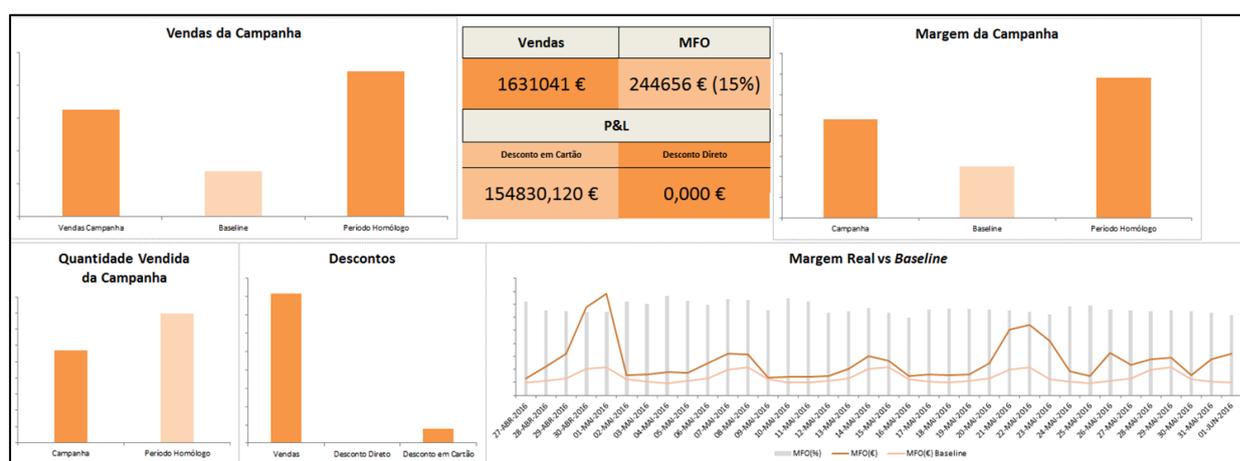


Figura E 1 - Quadro geral da ferramenta de acompanhamento

A ferramenta de acompanhamento introduziu a comparação dos resultados da campanha com um cenário teórico sem campanha. Assim é possível determinar o incremento de vendas e margem associadas à realização da campanha. Para além do quadro geral apresentado na Figura 1, a ferramenta serve-se da estrutura utilizada pelo simulador (Figura 2 do Anexo D) para a determinação da rentabilidade efetiva da campanha.

Nesta ferramenta, o *baseline* de vendas é obtido com base na metodologia das três semanas anteriores à campanha, utilizada para a determinação do impacto de campanhas históricas. O *baseline* de margem percentual foi definido como a média das três semanas anteriores. Esta margem é assumida como constante ao longo da campanha. O facto de o *baseline* de vendas ser determinado para cada dia possibilita um acompanhamento mais detalhado da campanha.

## ANEXO F: Resultados da análise estatística

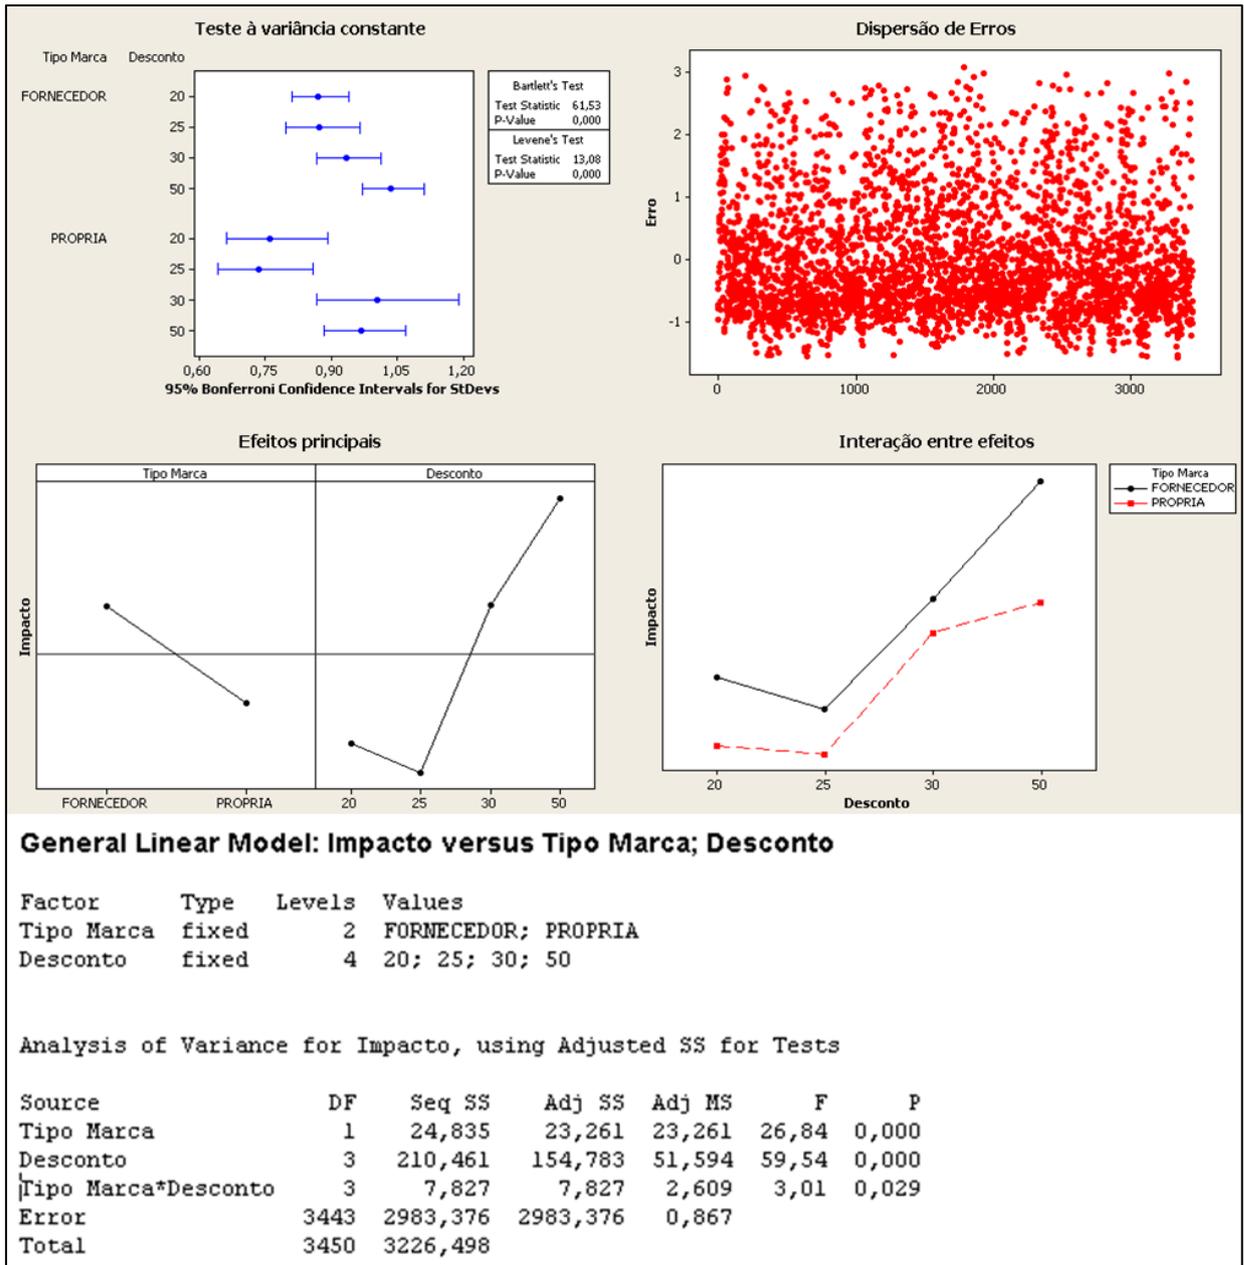


Figura F 1- Efeitos do tipo de marca e desconto na generalidade das campanhas

General Linear Model: Impacto versus Tipo Marca; Desconto						
Factor	Type	Levels	Values			
Tipo Marca	fixed	2	FORNECEDOR; PROPRIA			
Desconto	fixed	3	25; 30; 50			
Analysis of Variance for Impacto, using Adjusted SS for Tests						
Source	DF	Seq SS	Adj SS	Adj MS	F	P
Tipo Marca	1	12,1607	11,2514	11,2514	15,90	0,000
Desconto	2	32,4026	26,6165	13,3083	18,81	0,000
Tipo Marca*Desconto	2	3,0759	3,0759	1,5379	2,17	0,115
Error	649	459,1974	459,1974	0,7075		
Total	654	506,8365				

Figura F 2 - Tabela ANOVA ao tipo de marca e desconto na unidade de negócio de Fitness e Essentials

General Linear Model: Impacto versus Tipo Marca; Desconto						
Factor	Type	Levels	Values			
Tipo Marca	fixed	2	FORNECEDOR; PROPRIA			
Desconto	fixed	3	25; 30; 50			
Analysis of Variance for Impacto, using Adjusted SS for Tests						
Source	DF	Seq SS	Adj SS	Adj MS	F	P
Tipo Marca	1	16,534	9,740	9,740	9,27	0,002
Desconto	2	37,471	34,382	17,191	16,36	0,000
Tipo Marca*Desconto	2	2,320	2,320	1,160	1,10	0,332
Error	808	849,277	849,277	1,051		
Total	813	905,603				

Figura F 3 - Tabela ANOVA ao tipo de marca e desconto na unidade de negócio de Casual

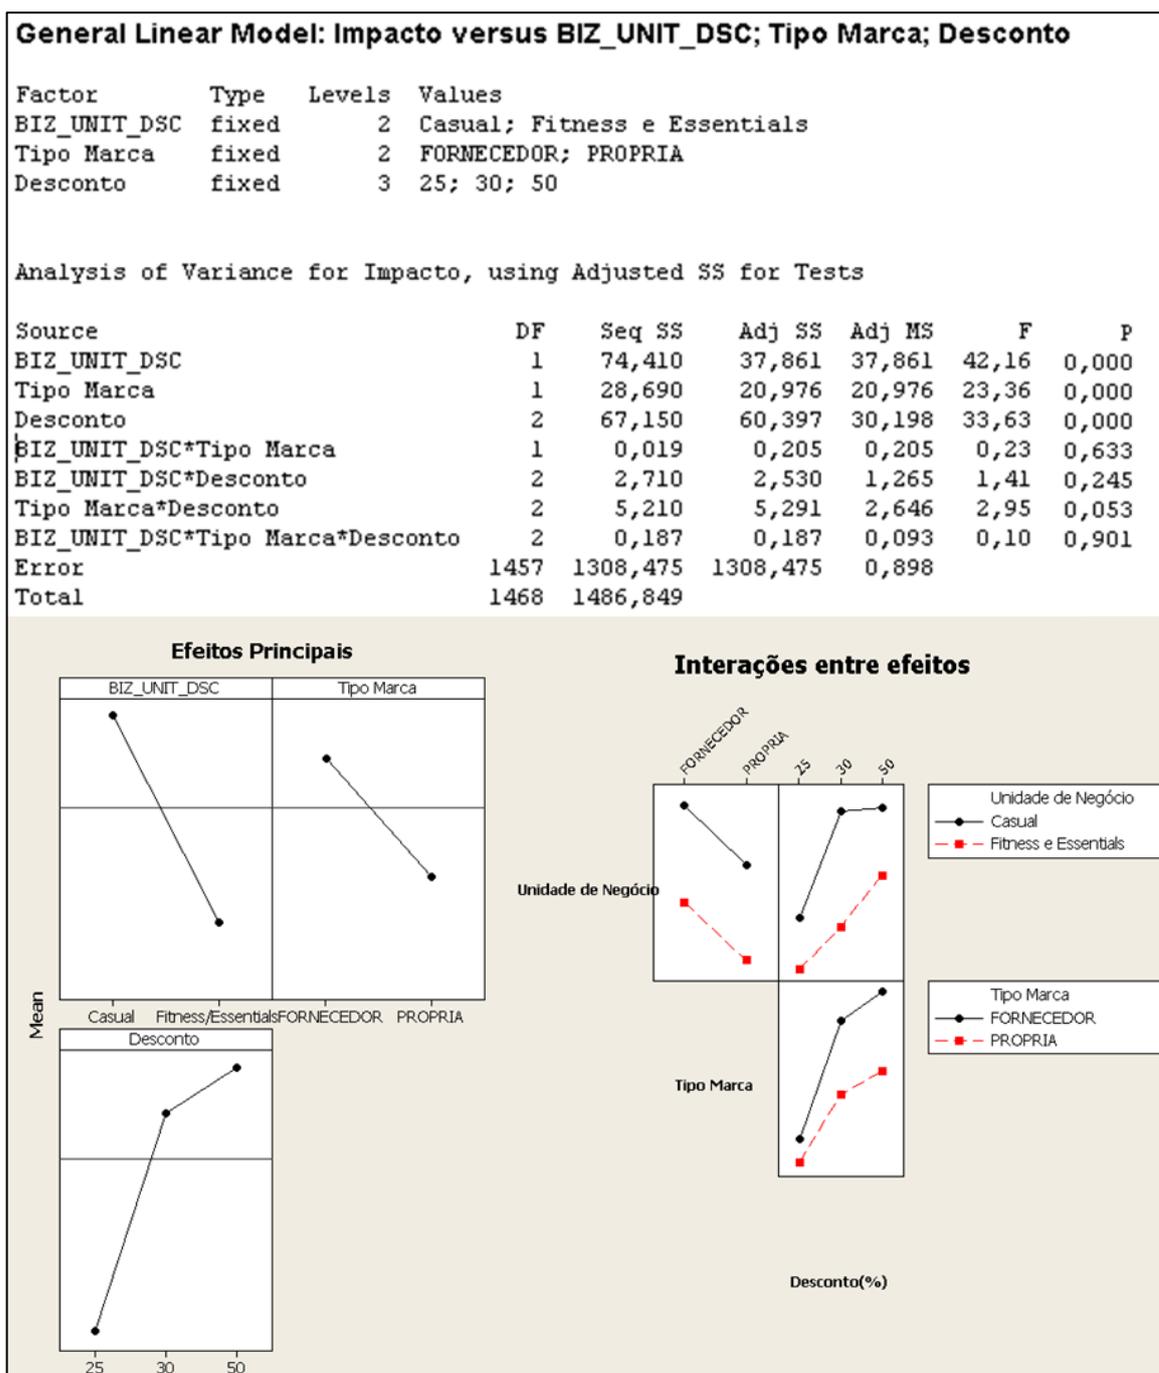


Figura F 4 - Efeitos do tipo de marca e desconto nas unidades de negócio de Casual e Fitness e Essentials

### One-way ANOVA: Impacto versus CAT\_DSC

Source	DF	SS	MS	F	P
CAT_DSC	6	28,582	4,764	7,09	0,000
Error	903	606,687	0,672		
Total	909	635,269			

S = 0,8197 R-Sq = 4,50% R-Sq(adj) = 3,86%

Figura F 5 - Tabela ANOVA para o efeito da categoria no impacto promocional

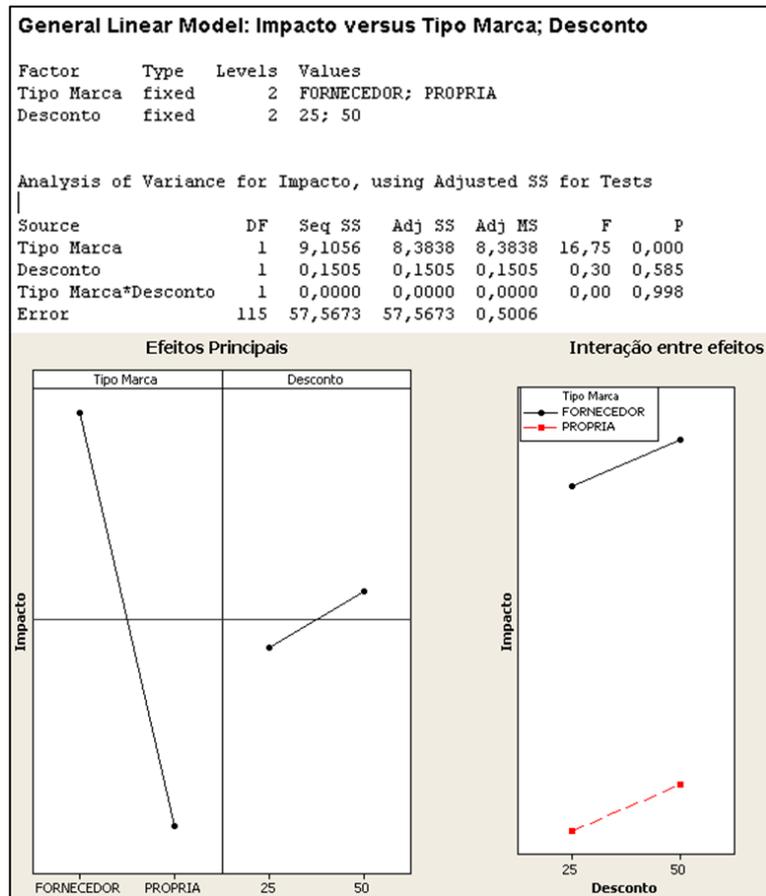


Figura F 6 - Efeitos do tipo de marca e desconto na categoria Essentials Têxtil Júnior

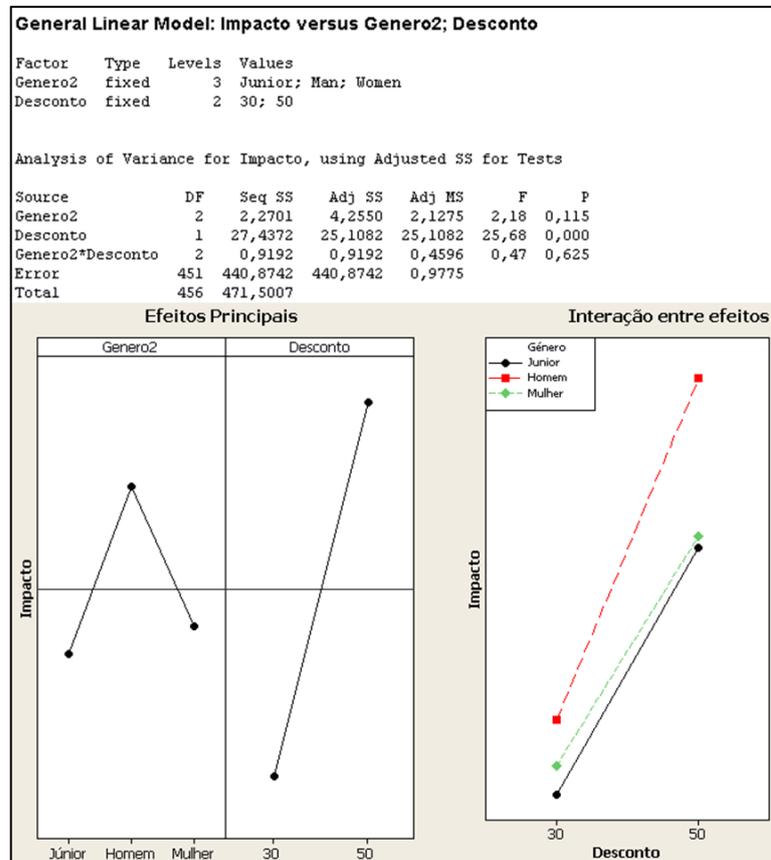


Figura F 7 - Efeitos do género e desconto na tipologia de calçado

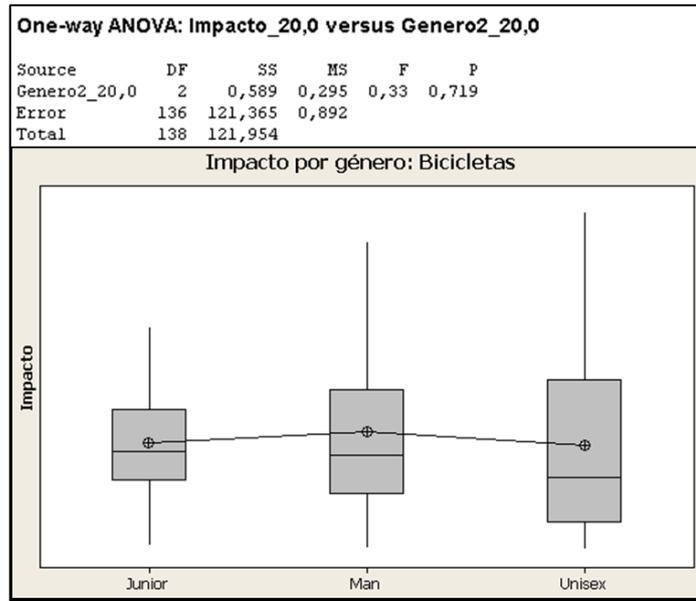


Figura F 8 - Efeitos do género na tipologia de bicicletas

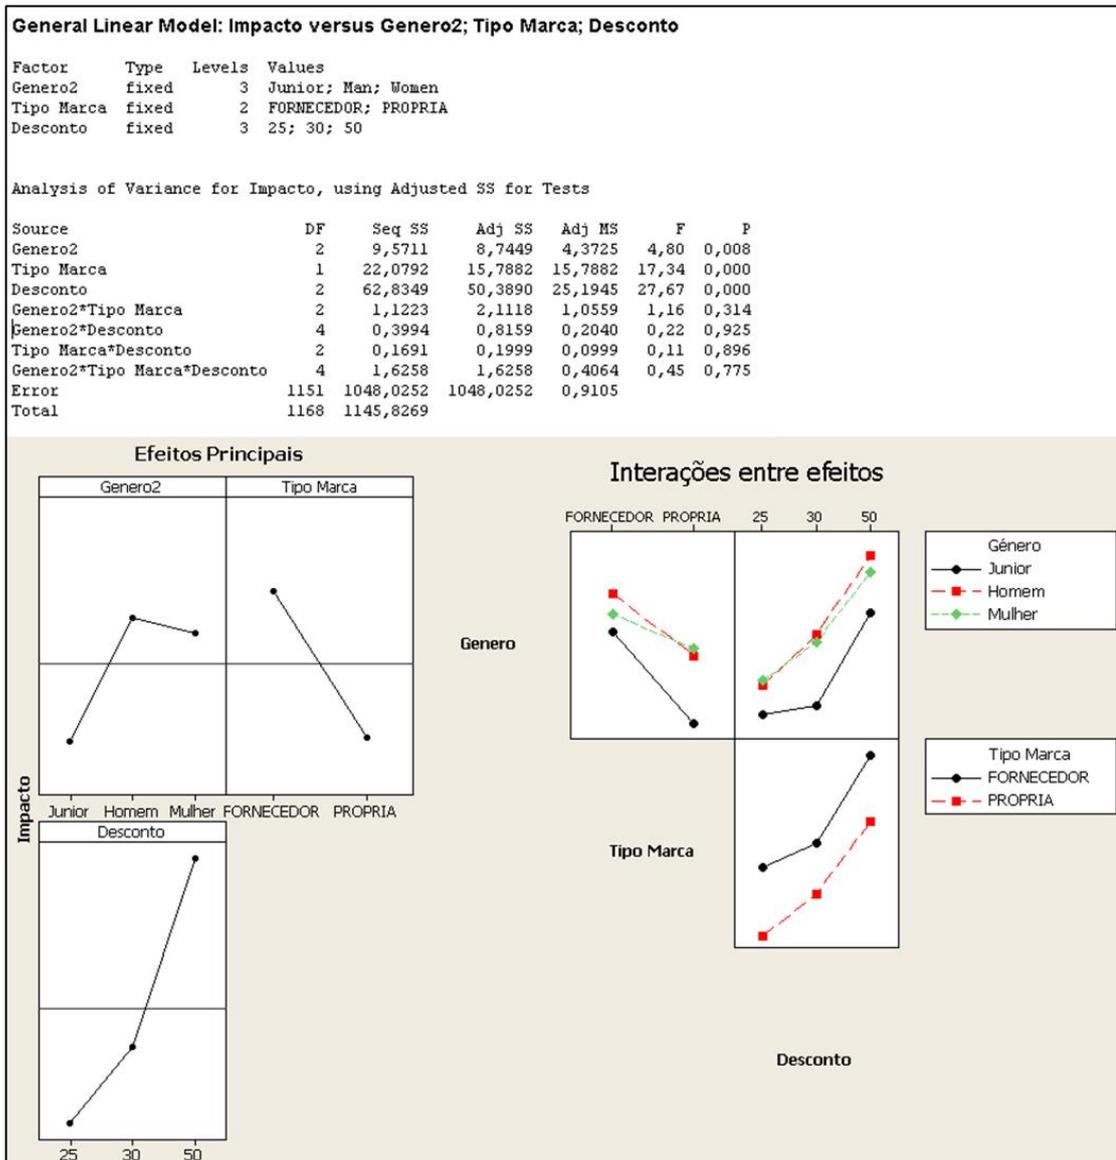


Figura F 9 - Efeitos do género, tipo de marca e desconto na tipologia de têxtil

General Linear Model: Impacto versus Genero2; Tipo Marca						
Factor	Type	Levels	Values			
Genero2	fixed	3	Junior; Man; Women			
Tipo Marca	fixed	2	FORNECEDOR; PROPRIA			
Analysis of Variance for Impacto, using Adjusted SS for Tests						
Source	DF	Seq SS	Adj SS	Adj MS	F	P
Genero2	2	6,7769	4,1222	2,0611	2,83	0,060
Tipo Marca	1	21,6626	20,2488	20,2488	27,78	0,000
Genero2*Tipo Marca	2	0,4551	0,4551	0,2275	0,31	0,732
Error	422	307,5509	307,5509	0,7288		

Figura F 10 - Tabela ANOVA ao género e tipo de marca em têxtil na unidade de negócio de Fitness e Essentials

## ANEXO G: Resultados da previsão de impactos

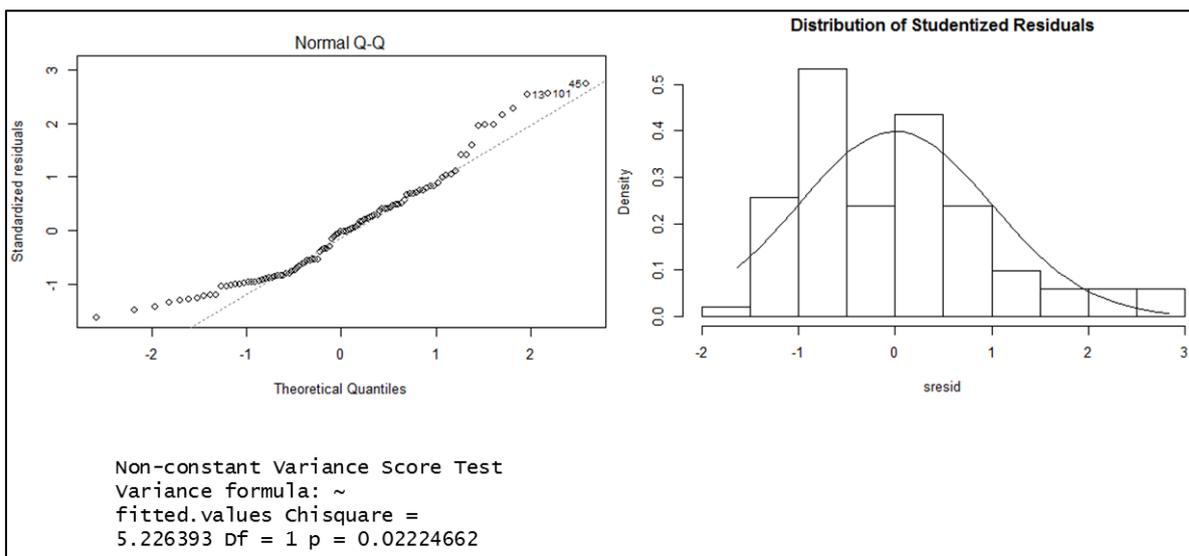


Figura G 1 - Verificação das condições impostas aos erros pela regressão múltipla