



UNIVERSIDADE
LUSÓFONA
DO PORTO

Vasco Manuel Martins Ferreira

O impacto do Working Capital na rentabilidade: análise de empresas vitivinícolas de Portugal, Espanha, França e Itália

Dissertação de Mestrado
Mestrado em Gestão

Trabalho realizado sob orientação de
Prof^a. Doutora Maria Teresa Ribeiro Candeias

Fevereiro 2019



UNIVERSIDADE
LUSÓFONA
DO PORTO

Vasco Manuel Martins Ferreira

O impacto do Working Capital na rentabilidade: análise de empresas vitivinícolas de Portugal, Espanha, França e Itália

Dissertação de Mestrado
Mestrado em Gestão

Dissertação defendida em provas públicas
na Universidade Lusófona do Porto no dia 06/02/2019,
perante o júri seguinte:
Presidente: Prof^ª. Doutora Maria Isabel Andrés Marques
Arguente: Prof. Doutor Rui António Macário Dias Osório
Orientador:
Prof^ª. Doutora Maria Teresa Ribeiro Candeias

Fevereiro 2019

É autorizada a reprodução integral desta tese/dissertação apenas para efeitos de investigação,
mediante declaração escrita do interessado, que a tal se compromete.

“ Strapped by tight credit and plummeting sales, businesses have overhauled the way they manage supply chains, inventory, production practices and staffing. ”

(Janet Yellen)

Dedicatória

Dedico este trabalho à minha família: aos meus pais pela paciência e dedicação e ao meu irmão pela boa disposição e colaboração.

Obrigado pelo apoio que me deram, as boas opiniões e críticas que me ajudaram a procurar fazer sempre o melhor de forma eficiente e eficaz.

Agradecimentos

Agradeço à minha orientadora, a Sra. Professora Doutora Teresa Candeias, pelas críticas construtivas, o apoio e disponibilidade durante todo o ano e as valiosas sugestões para a elaboração de um trabalho com maior valor e qualidade.

Agradeço também ao meu amigo Luís que se disponibilizou e me apoiou sempre que precisei.

Resumo

O Working Capital é uma ferramenta fundamental na gestão das empresas. Deloof (2003) estudou o impacto deste nas empresas da Bélgica e concluiu que existe uma relação com a rentabilidade das empresas. Lazaridis (2006) encontrou também uma relação entre o Working Capital (WCM) e a rentabilidade das empresas da Grécia. O objetivo deste estudo é encontrar a relação entre a rentabilidade das empresas vitivinícolas de Portugal, Espanha, França e Itália e a sua rentabilidade através da correlação de Pearson e de redes neuronais. Os dados foram obtidos através da base de dados europeia “Amadeus” e foram estudadas 324 empresas após a remoção de *outliers*. As redes neuronais são um tópico abordado cada vez mais no âmbito empresarial e é uma ferramenta que tenta encontrar a melhor forma de se prever o resultado baseando-se nas variáveis estudadas. Através deste estudo encontrou-se que existe uma correlação negativa entre o Ciclo Operacional e a rentabilidade das empresas francesas, uma correlação negativa entre o Prazo Médio de Recebimento e a rentabilidade das empresas italianas e uma correlação positiva entre o Ciclo de Conversão de Caixa e a rentabilidade das empresas portuguesas. A rede neuronal utilizada neste estudo não foi capaz de gerar uma previsão exata. No entanto, consegue prever uma tendência para as variáveis do Working Capital.

Palavras-chave: Working Capital, Ciclo de Conversão de Caixa, Rentabilidade, Empresas Vitivinícolas

Abstract

Working Capital is a key tool in business management. Deloof (2003) studied the impact of this on Belgium companies and concluded that there is a relationship with the profitability of companies. Lazaridis (2006) also found a relationship between the WCM and the profitability of Greek companies. The objective of this study is to find the relationship between the profitability of wine companies of Portugal, Spain, France and Italy and their profitability through the Pearson correlation and neural networks. The data used was obtained from the European database - "Amadeus" and 324 companies were studied after the removal of outliers. Neural networks are a topic that is increasingly addressed in the business environment and is a tool that tries to find the best way to predict the result based on the studied variables. Through this study it was found that there is a negative correlation between the Operational Cycle and the profitability of the French companies, a negative correlation between Days Sales Outstanding and the profitability of Italian companies and a positive correlation between the Cash Conversion Cycle and profitability of Portuguese companies. The neural network used in this study was not able to generate an accurate prediction. However, it can predict a trend for the Working Capital variables.

Keywords: Working Capital, Cash Conversion Cycle, Profitability, Wine Companies

Conteúdo

Introdução	1
I Revisão da Literatura	3
1.1 Conceito de Ciclo de Conversão de Caixa	30
1.2 Componentes do Ciclo de Conversão de Caixa	32
1.3 Rentabilidade das empresas	35
II Caracterização mundial do setor vitivinícola	39
2.1 Produção	40
2.2 Exportação	43
2.3 Importação	43
2.4 Consumo	45
III Metodologia	49
3.1 Problema do estudo	49
3.2 Pergunta de partida	49
3.3 Objetivos do estudo	50
3.4 Hipóteses do estudo	50
3.5 Construção das variáveis	51
3.6 Fonte dos Dados	53
3.7 Correlação de Pearson	55
3.8 Redes Neurais Artificiais	56
3.9 Estudo de caso das empresas vitivinícolas	63
IV Resultados	67
4.1 Outliers	67
4.2 Dados	67
4.3 Estatística Descritiva	72
4.4 Correlação das variáveis	79
4.5 Rede Neuronal Artificial	82
V Conclusão	89

Bibliografia	91
Apêndice	95
Dados das empresas vitivinícolas	95
Tabelas de Pesos da Rede Neuronal	103
Código fonte do programa de tratamento e análise dos dados e rede neuronal . . .	110
Anexos	123
Demonstração de Resultados - Diário da República	123

Índice de Abreviaturas e Siglas

AI	Inteligência Artificial
Back Propagation	Retropropagação
BREXIT	Britain Exit
CCC	Ciclo de Conversão de Caixa
CCE	Eficiência do Ciclo de Conversão de Caixa
DIO	Prazo Médio de Rotação de Inventário
DPO	Prazo Médio de Pagamento
Dropout Layer	<i>Layer</i> que elimina aleatoriamente alguns neurónios para a rede adaptar os pesos e diminuir a margem de erro.
DSO	Prazo Médio de Recebimento
EBIT	Resultado Operacional Líquido
EBITDA	Resultado Operacional Bruto
Epoch	Iteração do algoritmo de aprendizagem
FWC	Working Capital Financeiro
GWC	Working Capital Bruto
input	valores de entrada
just-in-time	Os inventários são mantidos num nível mínimo e a estrutura de produção é otimizada para nunca se esgotarem
Loss Function	função de custo
NLB	Saldo Líquido

NTC	Ciclo Operacional Líquido
NWC	Working Capital Líquido
OC	Ciclo Operacional
OMMDA	Overnight Money Market Deposit Account - Con- tas de depósito que geram uma taxa de juro “ <i>overnight</i> ” - taxas “ <i>swap</i> ”
outlier	Observação que se encontra destacada das restan- tes observações num conjunto de dados
output	resultado
OWC	Working Capital Operacional
RAI	Resultado Antes de Impostos
ReLU	Rectified Linear Unit
RLP	Resultado Líquido do Período
shareholders	Acionistas
Simple Random Sample	Amostra Simples Aleatória
test-set	Uma parte dos dados que será utilizada para testar o modelo de redes neuronais, após a sua validação.
training-set	Uma parte dos dados que será utilizada para trei- nar o modelo de redes neuronais.
VAL	Valor Atual Líquido
validation-set	Uma parte dos dados, retirada do training-set, que será utilizada para ajustar os parâmetros da rede neuronal.
WCM	Working Capital
WCR	Working Capital Requerido
XOR	“Ou” Exclusivo

Lista de Figuras

1	Requisitos de Capital Acumulado - Brealey et al. (2006)	18
2	Ciclo de Conversão de Caixa - Adaptado do modelo de Richards e Laughlin (1980)	35
3	Ciclo das finanças empresariais - Preve e Sarria-Allende (2010)	36
4	Produção mundial de vinho. Fonte: International Organization of Vine and Wine (2018)	43
5	Produção mundial de vinho. Fonte: International Organization of Vine and Wine (2018)	44
6	Importação por tipo de vinho dos países mais importadores do ano de 2017. Fonte: International Organization of Vine and Wine (2018)	45
7	Consumo de vinho <i>per capita</i> do mercado tradicional europeu. Fonte: Anderson et al. (2016)	46
8	Consumo de vinho <i>per capita</i> do mercado do novo mundo. Fonte: Anderson et al. (2016)	47
9	Consumo mundial de vinho. Fonte: Anderson et al. (2016)	47
10	Cota de mercado do vinho no mercado mundial. Fonte: Anderson et al. (2016)	48
11	Cota de mercado do Reino Unido nas exportações dos principais parceiros. Fonte: Anderson et al. (2017)	48
12	Diagrama de Venn sobre os sistemas de Inteligência Artificial - Goodfellow et al. (2016)	57
13	Estrutura de um neurónio natural - Cortez e Neves (2000)	58
14	Estrutura geral de um nodo - Cortez e Neves (2000)	58
15	Mínimos locais e globais (<i>Gradient Descent</i>) - Cortez e Neves (2000)	60
16	Estrutura de uma rede neuronal multi camada (<i>Multi Layer Perceptron</i>) - Cortez e Neves (2000)	61
17	Comparação da margem de erro entre a utilização de um Dropout Layer e sua não utilização - Reitermanová (2010)	65
18	Representação gráfica da variação das variáveis ao longo dos anos - Ciclo de Conversão de Caixa (CCC) e Prazo Médio de Pagamento (DPO)	69

19	Representação gráfica da variação das variáveis ao longo dos anos - Prazo Médio de Rotação de Inventário (DIO) e Prazo Médio de Recebimento (DSO)	70
20	Representação gráfica da variação das variáveis ao longo dos anos - Ciclo Operacional (OC) e Resultado Operacional Bruto (EBITDA)	71
21	Representação gráfica dos quartis do Ciclo de Conversão de Caixa das empresas	73
22	Representação gráfica dos quartis do Ciclo Operacional das empresas	74
23	Representação gráfica dos quartis do Prazo Médio de Recebimento das empresas	75
24	Representação gráfica dos quartis do Prazo Médio de Pagamento das empresas	76
25	Representação gráfica dos quartis do Prazo Médio de Rotação de Inventário das empresas	77
26	Representação gráfica dos quartis do Resultado Operacional Bruto das empresas	78
27	Estrutura da Rede Neuronal	83
28	Dispersão do Ciclo de Conversão de Caixa pelo EBITDA	83
29	Evolução da aprendizagem da rede neuronal	86
30	Resultados da rede neuronal artificial - tendência	87
31	Resultados da rede neuronal artificial - valor	87

Lista de Tabelas

1	Variáveis do estudo do <i>Working Capital</i> das empresas brasileiras de Ching et al. (2011)	11
2	Dados das empresas brasileiras do estudo de Ching et al. (2011) - Prazos Médios, Ciclo de Conversão de Caixa e Desempenho	12
3	Dados das empresas brasileiras do estudo de Ching et al. (2011) - Eficiência do Ciclo de Conversão de Caixa e Desempenho	13
4	Exemplo do WCM num balanço, Strischek (2002)	16
5	Tabela de resultados por quartil do estudo de Rehn (2012)	27
6	Tabela de dados das empresas finlandesas e suecas do estudo de Rehn (2012)	28
7	Variação da área sobre vinhas dos principais países - Fonte: International Organization of Vine and Wine (2017)	41
8	Produção de uvas dos principais países - Fonte: International Organization of Vine and Wine (2017)	42

9	Produção de uvas dos principais países - Fonte: International Organization of Vine and Wine (2017)	42
10	Exportação de vinho dos principais países (volume em mhl e valor em milhões de €) - Fonte: International Organization of Vine and Wine (2018) . .	44
11	Importação de vinho dos principais países (volume em mhl e valor em milhões de €) - Fonte: International Organization of Vine and Wine (2018) . .	45
12	Empresas produtoras de vinho	53
13	Anos empresariais por país	54
14	Tabela lógica “A XOR B”. (0 : <i>Falso</i> e 1 : <i>Verdadeiro</i>)	62
15	Comparação das médias dos países	68
16	Resultados da correlação de Pearson entre as variáveis do Working Capital e a rentabilidade	79
17	Resultados da correlação de Pearson entre as variáveis do Working Capital e a rentabilidade (cont.)	80
18	Resultados da correlação de Pearson entre as variáveis do Working Capital e a rentabilidade - resultados globais	80
19	Teste das Hipóteses h1 a h5	82
20	Teste das Hipóteses h1 a h5 - resultados globais	82
21	Variação da média do Ciclo de Conversão de Caixa	95
22	Variação da média do Prazo Médio de Pagamento	96
23	Variação da média do Prazo Médio de Rotação de Inventário	96
24	Variação da média do Prazo Médio de Recebimento	97
25	Variação da média do Ciclo Operacional	97
26	Variação da média do Resultado Operacional Bruto	98
27	Estatística das empresas espanholas	99
28	Estatística das empresas francesas	100
29	Estatística das empresas italianas	101
30	Estatística das empresas portuguesas	102
31	Pesos do Primeiro Layer	103
32	Pesos do Segundo Layer	104
33	Pesos do Segundo Layer (cont.)	105
34	Pesos do Segundo Layer (cont.)	106
35	Pesos do Segundo Layer (cont.)	107
36	Pesos do Output Layer	108
37	Bias do Primeiro Layer	109
38	Bias do Segundo Layer	109

39	Bias do Output Layer	109
40	Demonstração de Resultados - EBIT e EBITDA - Fonte: Diário da República, 1.ª série - N.º 143 - 24 de julho de 2015	123

Índice de Equações

1.1	Dimensão da Empresa	6
1.2	Alavancagem Financeira	9
1.3	Eficiência do Ciclo de Conversão de Caixa	11
1.4	Rácio de Endividamento	13
1.5	Working Capital Líquido	15
1.6	Ciclo Operacional Líquido	20
1.7	Exemplo de estimativa de financiamento necessário no WCM	21
1.8	Working Capital Requerido	21
1.9	Saldo Líquido	21
1.10	Fórmula de rentabilidade utilizada no estudo de Shin e Soenen (1998)	24
1.11	Rácio de Liquidez Geral	24
1.12	Fórmula de rentabilidade do estudo de Deloof (2003)	24
1.13	Rácio de Resultado Operacional Bruto	26
1.14	Ciclo de Conversão de Caixa	31
1.15	Working Capital	31
1.16	Ativos Correntes	31
1.17	Passivos Correntes	31
1.18	Ciclo Operacional	32
1.19	Prazo Médio de Pagamento	32
1.20	Prazo Médio de Rotação de Inventário	33
1.21	Prazo Médio de Recebimento	34
1.22	Ativos, Passivos e Capitais Próprios num balanço	36
3.6	Correlação de Pearson	55
3.7	Significância da Correlação de Pearson	55
3.8	Cálculo dos pesos de um nodo - Cortez e Neves (2000)	58
3.9	Valor do nodo - Cortez e Neves (2000)	58
3.10	Função de adição - Cortez e Neves (2000)	59
3.11	Erro Quadrático Médio	59
3.12	Regra <i>delta</i> ou <i>Widrow-Hoff</i> - Cortez e Neves (2000)	60

3.13	Função de ativação mais comum para redes neuronais - Rectified Linear Unit (ReLU) - Hahnloser et al. (2000)	60
3.14	Representação matemática de uma <i>Deep Neural Network</i> - Goodfellow et al. (2016)	61
3.15	Cálculo do valor do neurónio da camada de entrada	62
3.16	Cálculo do valor do neurónio da camada intermédia	62
3.17	Cálculo do valor do neurónio da camada de saída	63
3.18	Normalização Min-Max	64

Introdução

Com o aumento da competitividade do setor vitivinícola que está cada vez mais globalizado, as empresas têm que optar por novas formas de gestão para aumentar a sua rentabilidade. A crise de 2007 afetou foi um fator importante para a mudança do mercado vitivinícola mundial. Os países que tradicionalmente eram consumidores de vinho diminuíram o seu volume de consumo e novos países começaram a consumir e a produzir em maior escala. Thorpe (2009) concluiu que a produção de vinho nos países do novo mundo forçou os produtores do velho mundo a serem mais competitivos. A China está a entrar no mercado da vitivinicultura e começa a ter influência no mercado. Segundo Anderson e Wittwer (2013), o Britain Exit (BREXIT) vai influenciar o mercado, pois o Reino Unido é um país fundamental no mercado mundial do vinho. Para fazer face à maior competitividade e alterações no mercado, as empresas vitivinícolas têm que se adaptar e criar maior rentabilidade.

Com o aumento da importância da tomada de decisões na gestão das empresas, é necessário calcular o seu impacto na rentabilidade. No mínimo é necessário saber onde se pode mexer. As empresas passam a ter mais opções para alterar para além dos custos e das receitas. O aumento das vendas nem sempre é possível, pois representa um investimento e é difícil encontrar onde se pode cortar nos custos.

O Working Capital é uma ferramenta fundamental para a gestão das empresas. As variáveis que influenciam esta ferramenta são difíceis de controlar e ainda mais difíceis de calcular o impacto que têm na rentabilidade das empresas. O WCM é representado pelo Ciclo de Conversão de Caixa.

Deloof (2003) concluiu que existe uma relação negativa entre o Ciclo de Conversão de Caixa e o EBITDA para as empresas belgas. Lazaridis (2006) também encontrou uma relação negativa do Prazo Médio de Recebimento, Prazo Médio de Pagamento e CCC com a rentabilidade das empresas gregas. Estes estudo concluem que quando menor for o WCM, maior será a rentabilidade de uma empresa. No entanto, as empresas estudadas pertencem ao setor industrial, e não são comparáveis às empresas do setor vitivinícola. As empresas portuguesas também foram alvo de estudo por parte de Serrasqueiro (2014) e Russo (2013)

que encontraram correlações das variáveis do CCC com o EBITDA.

Este estudo tem como objetivo encontrar uma relação entre o WCM e o EBITDA das empresas de Portugal, Espanha, França e Itália do setor vitivinícola e analisa as variáveis do CCC de 324 empresas e 521 anos empresariais. O primeiro passo para encontrar a relação é analisar os dados através da correlação de Pearson e apurar a sua significância. O segundo passo é criar uma rede neuronal artificial e verificar se é possível compreender como o WCM influencia a rentabilidade das empresas.

Este estudo está dividido em quatro partes:

- a revisão dos estudos realizados no âmbito do WCM que procura perceber como foram realizadas as análises aos dados das empresas de diversos países;
- a caracterização mundial do setor vitivinícola que verifica a evolução do mercado ao longo de vários anos, os países produtores e os grandes *players* de mercado, tal como a entrada da China;
- a metodologia de análise dos dados e como são construídas as variáveis do CCC, como se procede ao cálculo da correlação de Pearson e à construção de uma rede neuronal artificial;
- e os resultados das correlações de Pearson e da rede neuronal artificial.

Capítulo I

Revisão da Literatura

A *Gestão do Working Capital (WCM)*, é uma área frequentemente abordada pelas instituições académicas com o intuito de investigar qual a sua relação com o desempenho das empresas.

Diferentes autores utilizam diferentes variáveis para calcular o WCM. Por exemplo, Plant (2007) e Prat (2003) utilizam os ativos correntes e os passivos correntes e afirmam que esta gestão é um componente importante das finanças empresariais. No entanto, Lazaridis (2006), Gill et al. (2010) e Deloof (2003) utilizam o Ciclo de Conversão de Caixa como variável do Working Capital.

Segundo Deloof (2003), a forma como os prazos de pagamento, prazos de recebimento e inventários são geridos tem um impacto significativo na rentabilidade das empresas e Lazaridis (2006) obteve resultados que mostram que existe uma significância estatística entre a rentabilidade e o CCC.

Outros estudos indicam que empresas com alto rendimento seguem políticas de crédito dirigidas aos clientes para segurar o capital na forma de inventários. Por isso, os prazos médios de pagamento do financiamento têm tendência para aumentar pelo facto do custo dos mesmos ser redireccionado para os clientes. Por outras palavras, pelo facto de aumentar o número de clientes, visto que há mais crédito, e por sua vez o número de vendas, estas empresas precisam de comprar mais matéria-prima e aumentar a produção fazendo com que aumente o valor do inventário.

De acordo com Wilner (2000) a maioria das empresas utiliza extensivamente o crédito apesar do custo ser mais elevado e esse custo geralmente representa mais de 18% dos ativos das mesmas. Da mesma forma, Deloof (2003), através do Banco Nacional da Bélgica, concluiu que em 1997 as contas de pagamento representavam 13% dos ativos enquanto as

contas de recebimento e os inventários representavam 17% e 10% respetivamente. Summers e Wilson (2000) reportaram que, no Reino Unido, mais de 80% das transações diárias são feitas através de crédito.

Raheman e Nasr (2007), na análise de empresas paquistanesas, referem que o WCM afeta a liquidez das empresas e também a sua rentabilidade. Estes autores apuraram que, nas 94 empresas paquistanesas, a relação entre o WCM e o seu desempenho tem uma correlação de Pearson negativa. O mesmo acontece com Lazaridis (2006) nas empresas gregas, com Gill et al. (2010) nas empresas americanas, com Padachi (2006) nas empresas mauritanas (África Oriental) e com Deloof (2003) nas empresas belgas.

No estudo do WCM de Gill et al. (2010), foram utilizados oito componentes:

- Prazo Médio de Recebimento;
- Prazo Médio de Pagamento;
- Prazo Médio de Rotação de Inventário;
- Working Capital;
- Dimensão da empresa;
- Rácio de endividamento financeiro;
- Rácio de ativos fixos;
- Resultado Operacional Bruto.

Raheman e Nasr (2007) afirmam que adiar o pagamento aos fornecedores faz com que as empresas tenham margem para analisar a viabilidade de produtos financeiros derivados e assim flexibilizar as suas fontes de financiamento.

Segundo Lazaridis (2006), as empresas podem obter melhores resultados se gerirem corretamente o WCM e otimizarem os níveis de Contas de Clientes, Contas de Fornecedores e Inventário. Estes podem ser geridos de diferentes formas para maximizar o lucro e acelerar a taxa de crescimento da empresa. O WCM e as estruturas de capital são duas áreas muito estudadas para aumentarem a rentabilidade das empresas.

Para este autor, as empresas em forte crescimento deverão seguir uma política de crédito ao cliente mais restritiva enquanto empatam mais capital na forma de inventário. Com isto,

o valor nas contas de fornecedores irá aumentar tal como o seu prazo de pagamento e irá divergir o custo da empresa para os clientes. No entanto, deve ter-se em atenção que o crédito ao cliente é um veículo para atrair novos clientes e não deve ser demasiado restringido. Sendo assim, a decisão de optar por uma política de crédito mais aberta ou mais restritiva, cabe à empresa e esta deverá fazer estudos de marketing para apurar o tipo e a quantidade de clientes que serão afetados por esta política.

Dado as contas de clientes, para a maior parte das grandes empresas, terem um investimento significativo, as políticas de crédito e as práticas da empresa poderão ser fatores decisivos para o valor da empresa.

Lazaridis (2006) concluiu, através da análise de regressão linear, que o Resultado Operacional Líquido (EBIT) está negativamente correlacionado com o número de dias do DSO, DPO e WCM. Isto significa que as empresas mais rentáveis adiam ao máximo possível o prazo de pagamento aos fornecedores e que um menor WCM gera mais lucro.

Para além disso, obteve também o resultado que existe uma relação negativa entre o EBITDA e o inventário, sendo que quanto maior o inventário, menor será o WCM disponível. No entanto, este resultado não é estatisticamente significativo.

Neste estudo, os dados sugerem que empresas de menor rentabilidade procuram diminuir o prazo médio de recebimento numa tentativa de diminuir a falta de capital no seu WCM e também que, pelo facto da correlação negativa entre resultado e o número de dias do inventário, no caso de uma quebra no volume de vendas a empresa será forçada a tomar decisões não rentáveis numa tentativa de segurar capital.

Sendo assim, Lazaridis (2006) sugere que os gestores podem criar lucro para as suas empresas através de uma gestão eficaz do WCM e de cada um dos seus componentes (prazo médio de recebimento, prazo médio de pagamento e inventário).

Ali e Hassan (2010) analisaram 37 empresas suecas registadas na bolsa de valores através da análise de regressão e testaram várias hipóteses para apurar a relação entre a gestão do WCM e a sua rentabilidade dos anos 2004 a 2008. Estes autores referem também que no passado, as empresas preferiam ter um valor elevado no WCM para fazerem face às suas obrigações financeiras, mas que atualmente, com a evolução tecnológica e novas formas de gestão dos ativos correntes, a gestão do mesmo é considerada um peso para as empresas.

Para Ali e Hassan (2010), no seu estudo do WCM nas empresas suecas, não foi encontrada uma relação entre o WCM e o EBITDA e que os gestores não conseguem aumentar a rentabilidade através de novas políticas de gestão do WCM. No entanto, concluíram que os

ativos correntes são o fator mais importante do WCM.

Nestas empresas, verificou-se que se tende a aumentar o prazo de pagamento aos fornecedores e o prazo de pagamento do financiamento obtido. Ali e Hassan (2010) afirmam que este processo aumenta a liquidez, mas questionam o facto das empresas utilizarem esse capital como reserva de caixa em vez de o utilizarem em investimentos de curto prazo, como é o caso de títulos (*securities*) de curto prazo. Sendo assim, as empresas diminuem o risco de terem dívidas acumuladas a curto prazo, mas afeta a rentabilidade pelo facto do financiamento a longo prazo ter uma maior taxa de juro.

Esta abordagem assenta no financiamento dos ativos de curto prazo através de financiamento de curto prazo e no financiamento de ativos de longo prazo através de financiamento de longo prazo. Isto acontece porque os credores preferem que as empresas mantenham um nível baixo de ativos de curto prazo para assegurar as garantias do crédito.

Estes autores, tomaram como princípio que um WCM mais curto é resultado de uma política de gestão do WCM mais agressiva e que um mais longo é resultado de uma política mais defensiva, tal como referido por Lazaridis (2006). Para além do WCM, utilizaram também a dimensão da empresa, o rácio de ativos financeiros no total de ativos e a dívida financeira - dívidas que não fazem parte do Ciclo Operacional da empresa, ou seja, não representam dívidas aos fornecedores, mas sim dívidas de financiamento. A dimensão da empresa foi calculado através do logaritmo natural das vendas. A razão de ser utilizado o logaritmo natural nesta fórmula (e em muitas outras fórmulas em ciências sociais) é explicada por Gelman e Hill (2007):

Preferimos utilizar logaritmos naturais (isto é, logaritmos de base e) porque, tal como descrito anteriormente, coeficientes no logaritmo natural são diretamente interpretáveis como diferenças proporcionais aproximadas: com um coeficiente de 0.06, a diferença de 1 em x corresponde aproximadamente a 6% de diferença em y , e por aí em diante.

$$F = \ln(S) \tag{1.1}$$

Onde:

F = dimensão da empresa

S = Vendas

Os ativos financeiros incluem os empréstimos de curto e longo prazo e ajuda a perceber e explicar a relação entre o total de ativos e o financiamento externo - tal como referido por Lazaridis (2006). A fórmula dos ativos financeiros é composta pela soma dos seguintes valores:

- Investimentos em Capital Próprio;
- Rendimentos financeiros;
- Ativos para venda;
- Ativos disponíveis para venda;
- Derivados;
- Títulos;
- Outros rendimentos.

A dívida financeira é calculada através da soma das hipotecas de curto e longo prazo e dos empréstimos de curto e longo prazo.

Os resultados obtidos por Ali e Hassan (2010), mostram que existe pouca relevância entre o desempenho da empresa e os ativos financeiros, mas que existe uma relação forte entre a dívida financeira e o desempenho.

Estes autores não encontraram uma relação entre o WCM e a rentabilidade das empresas suecas porque a análise de regressão não conseguiu determinar uma relação entre as diferentes variáveis, sendo que nas três análises que fizeram aos dados, o valor obtido era 0 (zero).

No entanto, encontraram que a dívida financeira de curto prazo é a forma mais barata de financiamento para uma empresa e que pode aumentar a rentabilidade, que a dívida financeira tem uma pequena relação com os ativos fixos financeiros, que os dois juntos influenciam positivamente (correlação positiva) o EBIT e que a dimensão da empresa tem uma correlação negativa com o mesmo.

Devido a uma incoerência nos dados, não conseguiram definir uma correlação entre o WCM e os elementos que o compõem.

Para Ali e Hassan (2010), os resultados das regressões dos dados mostraram que existia uma relação negativa entre o EBITDA e o número de dias do prazo de recebimentos que,

para os autores, fazia sentido na forma em que um maior período de crédito que a empresa oferecia aos seus clientes para aumentar o número de vendas, resultava antes num aumento do nível de créditos incobráveis.

Tornou-se claro para estes autores, que as empresas suecas aumentavam a sua rentabilidade fazendo uso de dívidas financeiras para financiar as suas operações.

No estudo de Garg e Gumbochuma (2015) sobre o impacto do WCM nas empresas de África do Sul, os autores encontraram uma relação negativa entre o WCM e o EBITDA, uma relação negativa entre a rentabilidade e o rácio de dívida financeira e um impacto positivo do fundo de maneio e da rentabilidade, mas que não era estatisticamente significativo.

Estes autores encontraram também uma relação negativa entre a rentabilidade das empresas e a sua dimensão sendo que, as mais pequenas têm maior rentabilidade.

Neste estudo foi utilizado o Working Capital Líquido (NWC) e foi verificado que esconder os lucros para evitar os impostos é uma prática comum para as empresas dos mercados emergentes não listadas em bolsa, o que as torna menos adequadas como amostras da análise onde é necessário inferir baseando-se em dados financeiros sobre o WCM. O mesmo foi observado no estudo de Lazaridis (2006).

Tal como nos estudos anteriores, Garg e Gumbochuma (2015) utilizaram o EBITDA como variável da rentabilidade das empresas e a equação 1.1 como fórmula da dimensão da empresa. Estes autores fizeram uso de análises de regressão para apurar a correlação entre o WCM e a rentabilidade.

A relação entre a dimensão da empresa e a sua rentabilidade apresentou um valor 0.4960, o que se traduz numa correlação parcial positiva em que a rentabilidade está associada à dimensão da empresa. Isto significa que a rentabilidade de uma empresa aumenta se a sua dimensão (Volume de Vendas) aumentar, mas não na mesma magnitude.

Por outro lado, a relação entre a rentabilidade e o rácio de endividamento teve um resultado de -0.585, o que significa que existe uma correlação negativa em que à medida que o rácio de endividamento aumenta, a rentabilidade da empresa diminui, mas não na mesma magnitude.

A relação entre a rentabilidade e o WCM teve um resultado de -0.225 e foi considerada como estatisticamente relevante. Este resultado vai de acordo a outros estudos que encontraram também uma correlação negativa entre estes dois valores.

O pressuposto neste estudo é que não são analisados fatores específicos de cada empresa, mas sim fatores comuns a todas elas e que podem afetar a rentabilidade. Mesmo para empresas do mesmo setor, como no caso das empresas industriais, existem fatores específicos que se destacaram no teste de especificidade de Hausman e que são únicos para cada empresa. Daí, ter mais empresas na amostra dos dados aumenta a variabilidade e consequentemente, aperfeiçoa a precisão dos resultados da regressão e doutras análises estatísticas.

Garg e Gumbochuma (2015) concluíram que o principal objetivo da gestão do *Working Capital* numa empresa, é gerir os fundos de curto prazo que são necessários para as atividades diárias e que os das empresas do setor de retalho podem aumentar a rentabilidade com a redução do CCC.

Os resultados deste estudo são semelhantes aos estudos noutros países e indicam que o WCM e as suas componentes têm um impacto significativo nos níveis de rentabilidade das empresas.

$$L = \frac{S - C - ESS}{EBIT} \quad (1.2)$$

Onde:

- L = Alavancagem Financeira
- S = Vendas
- C = Consumos
- ESS = Fornecimentos e Serviços Externos
- $EBIT$ = Resultado Antes de Juros e Impostos

A alavancagem financeira está também negativamente correlacionada com a rentabilidade, o que significa que um maior valor da dívida financeira afeta adversamente o desempenho de uma empresa.

Ching et al. (2011) através do estudo do impacto do WCM das empresas brasileiras, obtiveram resultados que mostram que independentemente do tipo de empresa, a gestão do WCM é igualmente importante e que, gerir os inventários e o CCC a um nível ótimo gera mais lucro nas empresas.

Para estes autores, o WCM é uma ferramenta de gestão importante, pois representa uma fonte de rendimento numa era em que as empresas estão inseridas num mercado global de

preços baixos e que precisam de financiamento para se expandirem, interna ou externamente, para investirem em novas tecnologias e produtos ou para reduzirem a sua dívida.

A Dell (empresa de computadores), em 1998 tinha um Prazo Médio de Recebimento de 36 dias, Prazo Médio de Rotação de Inventários de 7 dias e Prazo Médio de Pagamento de 51 dias, o que se traduz numa gestão eficiente e eficaz do WCM e que resultou numa margem bruta de 2 722 milhões de dólares nesse mesmo ano face a 1 666 milhões de dólares do ano de 1997.

No ano de 2006, um estudo sobre WCM feito pela CFO Magazine, apurou que houve uma evolução geral nas variáveis que o compõem ao longo dos anos nas empresas brasileiras e um estudo feito pela *Deloitte* em 2007 obteve resultados que mostram que 48% das 490 pequenas e médias empresas analisadas utilizam capital interno (principalmente lucro e WCM) como financiamento para as suas operações, seguido de empréstimos e mercados de capitais.

A análise dos dados foi feita através de 2 amostras: uma primeira amostra continha 16 empresas com gestão intensiva do WCM e uma segunda amostra que continha 16 empresas com gestão intensiva de capitais fixos.

Estes autores, baseando-se nos estudos anteriores do WCM, procuraram comprovar a existência de uma relação negativa forte entre o CCC nas empresas brasileiras. Outros autores, nomeadamente Raheman e Nasr (2007), referiram que existia uma relação negativa entre liquidez e rentabilidade, que significa que uma empresa com maior liquidez é uma empresa com menor rentabilidade e vice-versa.

Ching et al. (2011) optaram por divergir a sua análise de outros estudos, na medida em que utilizaram dois tipos de empresas e mediram o desempenho das empresas através de três formas diferentes. Estes autores introduziram no seu estudo, a Eficiência do Ciclo de Conversão de Caixa, que nos indica o desempenho da gestão do Ciclo de Conversão de Caixa em relação ao volume de vendas.

Variáveis do Estudo	
Empresa	Empresas com gestão intensiva de <i>Working Capital</i> Empresas com gestão intensiva de capitais fixos
	Ativos Financeiros Fixos dimensão da empresa (equação 1.1) Rácio de Dívida Financeira
	Vendas Retorno sobre Ativos Retorno sobre o Capital Próprio
<i>Working Capital</i>	Ciclo de Conversão de Caixa: - Prazo Médio de Pagamentos - Prazo Médio de Recebimentos - Prazo Médio de Rotação de Inventários Eficiência do Ciclo de Conversão de Caixa

Tabela 1: Variáveis do estudo do *Working Capital* das empresas brasileiras de Ching et al. (2011)

A fórmula para o cálculo da Eficiência do Ciclo de Conversão de Caixa (CCE) é a seguinte:

$$CCE = \frac{R + I - P}{S} \quad (1.3)$$

Onde:

CCE = Eficiência do Ciclo de Conversão de Caixa

R = Contas de Clientes

I = Inventários

P = Contas de Fornecedores

S = Vendas

Estes autores obtiveram resultados que mostram que a gestão dos prazos médios de pagamento e de recebimento e rotação de inventários é fraca e que as empresas menos rentáveis esperam mais para pagar aos fornecedores.

Apesar de alguns dos indicadores apresentarem correlações negativas com o desempenho, o CCC mostrou-se mais importante que a liquidez geral para a rentabilidade das empresas.

Estes autores notaram que no estudo do WCM de Deloof (2003), o Prazo Médio de Pagamento apresentava uma relação negativa com o desempenho, enquanto no estudo de Lazaridis (2006) apresentava uma relação positiva.

Os dados das empresas brasileiras mostraram que existem empresas com dívidas financeiras de 95% sobre o capital da empresa, que o impacto do WCM afeta a rentabilidade em 6%, que o valor médio do CCC (-16 dias) do primeiro tipo de empresas é muito superior ao valor médio do segundo tipo de empresas (55 dias), que os prazos médios de recebimentos para cada tipo de empresa têm em média 33 dias e 63 dias respectivamente, e que o prazo de rotação de inventários tem uma média 50 dias e 47 dias para cada tipo de empresa. Os dados mostram também que existe uma relação negativa entre os dias de inventário e o CCC.

A seguinte tabela mostra os dados obtidos neste estudo:

Tabela de Dados								
	DSO		DIO		WCM		Desempenho (%)	
	Tipo 1	Tipo 2	Tipo 1	Tipo 2	Tipo 1	Tipo 2	Tipo 1	Tipo 2
Média	33.0	62.6	50.2	47.3	-15.5	55.1	8	6
Mediana	29.6	71.2	44.4	43.4	9.0	55.5	5	7
Desvio Padrão	20.0	25.4	27.9	20.0	85.1	45.7	23	7
Máximo	102.7	99.4	184.1	108.8	92.9	133.8	71	44
Mínimo	1.4	13.9	15.7	18.6	-274.4	-50.8	-99	-12

Tabela 2: Dados das empresas brasileiras do estudo de Ching et al. (2011) - Prazos Médios, Ciclo de Conversão de Caixa e Desempenho

O que esta tabela nos diz é que apesar de as empresas que não efetuam uma gestão intensiva do WCM terem uma média de rentabilidade superior, não se traduz no argumento de que não é necessário controlar o WCM, muito pelo contrário, este é importante e tem uma maior probabilidade de sucesso para uma empresa, visto que as empresas que não o controlam de forma intensiva terem uma rentabilidade que varia entre os 71% e os -99%, enquanto que as que o fazem, têm um variação compreendida entre os 44% e os -12%.

Para além disso, Ching et al. (2011) observaram, também, que o Prazo Médio de Rotação de Inventários tem uma relação negativa com o CCC. Isto significa que um maior número de dias de rotação de inventários, resulta num menor número de dias de CCC. Estes autores obtiveram também relações negativas do Prazo Médio de Rotação de Inventário e do Rácio de Dívida Financeira com o valor de Vendas, que indica que uma diminuição da dívida financeira e do número de dias de rotação de inventários geram maior rentabilidade para as empresas. Nestes resultados foi observado que as empresas brasileiras aumentam o Prazo Médio de Recebimento de forma a aumentar o número de vendas.

Ching et al. (2011) concluíram que não existe significância estatística para comprovar a hipótese de que existe uma relação negativa entre o CCC e o desempenho das empresas, até porque os resultados mostraram uma relação positiva. Por outro lado, os autores encontraram

uma relação negativa entre a Eficiência do CCC e o desempenho.

Tabela de Dados				
	CCE (%)		Desempenho (%)	
	Tipo 1	Tipo 2	Tipo 1	Tipo 2
Média	-5	15	8	6
Mediana	2	14	5	7
Desvio Padrão	24	13	23	7
Máximo	26	42	71	44
Mínimo	-76	-14	-99	-12

Tabela 3: Dados das empresas brasileiras do estudo de Ching et al. (2011) - Eficiência do Ciclo de Conversão de Caixa e Desempenho

Isto indica que, tanto para as vendas, como para o retorno sobre ativos, a gestão do WCM é igualmente importante para os dois tipos de empresas, porém a forma como este é gerido varia conforme o tipo de empresa. Os resultados mostram que este é melhorado através da diminuição dos dias do Prazo Médio de Rotação de Inventário.

O impacto das variáveis do WCM nas vendas e no retorno sobre ativos, foi considerado estatisticamente relevante porque explica, através de regressão linear, 12.5% e 16.5% respectivamente nas empresas do tipo 1 e 21.7% e 18.4% das empresas de tipo 2. O impacto da CCE mostrou-se muito relevante para os dois tipos de empresas. Para o retorno sobre ativos, a variável com mais impacto foi o Prazo Médio de Rotação de Inventário e o rácio de endividamento tem uma relação negativa com o mesmo.

As variáveis que mais afetam o desempenho das empresas que gerem intensivamente o WCM são a CCE e o Prazo Médio de Rotação de Inventário, enquanto para as empresas que gerem intensivamente os ativos fixos, as mais impactantes são o CCC e o rácio de Endividamento.

$$D = \frac{L}{A} \quad (1.4)$$

Onde:

D = Rácio de Endividamento

L = Passivo

A = Ativos

No estudo de Serrasqueiro (2014) sobre o impacto do WCM nas empresas portuguesas de 2001 a 2006, os resultados mostraram que os gestores devem otimizar a gestão das suas componentes (Prazos Médios de Recebimento, Pagamento e Rotação de Inventário) para aumentar a sua rentabilidade.

Tal como no estudo do WCM de Deloof (2003) e Padachi (2006), Serrasqueiro (2014) também utilizou como fórmula do WCM o Ciclo de Conversão de Caixa. No entanto, o resultado deste estudo diverge dos resultados dos outros estudos. O CCC não se mostrou estatisticamente relevante para a rentabilidade das empresas portuguesas. Isto foi causado, provavelmente, pela endogeneidade, isto é, existem pelo menos dois fatores do WCM que estão associados entre si, não permitindo que fossem apuradas as correlações do CCC com a rentabilidade - o mesmo foi verificado por Deloof (2003).

Segundo Serrasqueiro (2014), na teoria do WCM, mais um dia no CCC significaria que as empresas teriam que esperar mais tempo para recuperarem o capital investido nas suas operações e que o capital estaria amarrado ao *Working Capital*.

Nos dados analisados, verifica-se que, por um lado, o aumento do prazo de recebimento para facilitar os créditos aos clientes, tem como resultado um aumento do volume de vendas, por outro lado, uma maior rigidez no prazo de pagamento, leva a um aumento do retorno sobre ativos. O efeito de uma política mais restritiva sobressai à política de facilidade de crédito no que toca a um maior impacto na rentabilidade das empresas. Deloof (2003) sugere que a explicação destes resultados está no facto de, normalmente, as empresas menos rentáveis pagarem mais tarde aos seus fornecedores. E o impacto negativo na rentabilidade pode ser explicado pelo maior custo para os fornecedores darem crédito que levará a uma má relação entre ambos e a uma diminuição das transações. O custo para a empresa, por não fazer uso dos descontos de pronto-pagamento dado pelos fornecedores, pode estar implícito no impacto negativo na rentabilidade. A rentabilidade diminui, também, com o aumento do número de dias de inventário. Tal como esperado, isto significa que, manter o inventário menos tempo, reduz os custos e tem um impacto positivo na rentabilidade das empresas. O CCC é utilizado como medida do WCM, mas na análise feita por este autor, esta situação não foi verificada por falta de significância demonstrada nos resultados.

Segundo o autor, as empresas precisam de criar valor para atrair os shareholders a investir mais na empresa, e o WCM pode ser incluído como um dos fatores que cria mais valor. Este autor refere também que este trabalho teve algumas limitações no que toca aos dados das empresas. O período analisado foi de 2001 a 2006 e neste período, Portugal estava a atravessar um momento de crise e muitas das empresas tiveram que ser excluídas da amostra, pois fecharam durante o período de análise deste estudo. No final, foram analisadas 3360

empresas, registradas na base de dados da *Bloomberg*.

A variável “dimensão da empresa”, calculada pela fórmula 1.1, tem uma relação negativa com a rentabilidade. Isto vai contra a teoria que “empresas grandes têm maior rentabilidade”. Nos dados obtidos, empresas mais pequenas declararam maior rentabilidade. O aumento das vendas tem um impacto positivo na rentabilidade, que significa que, empresas em crescimento na sua atividade operacional, têm um efeito positivo no retorno sobre ativos.

Rehn (2012) introduziu no seu estudo do WCM o Teorema da Separação de *Fisher*, que explica que as empresas devem evitar a confusão entre investimento e financiamento. Este teorema relaciona-se com o WCM na medida em que as empresas devem separar “quanto investir no WCM” e “como vão financiar esse investimento”. Por isso, este autor utilizou duas medidas de WCM:

- NWC: investimento que é necessário para as contas a receber, inventários e caixa;
- Working Capital Bruto (GWC): diferença entre ativos correntes e passivos correntes - financiamento de curto prazo e contas de fornecedores.

O NWC indica quanto do seu capital de longo prazo é necessário investir no WCM. Este pode também tomar valores negativos, que representam que a empresa tem mais passivo corrente do que ativo corrente. De acordo com o Teorema de *Fischer*, o GWC é o investimento e o NWC é o financiamento. Para este autor, as empresas têm que gerir estes dois fatores aquando da otimização e da maximização do lucro e da liquidez.

$$NWC = C + MI + TAR + I - TAP \quad (1.5)$$

Onde:

NWC = Working Capital Líquido

C = Caixa e Equivalentes

MI = Investimentos

TAR = Contas de Clientes

I = Inventário

TAP = Contas de Fornecedores

Tabela de Ativos e Passivos Correntes			
	20xx		20xx
Caixa	xx	<u>Contas de Fornecedores</u>	xx
Títulos	xx	Divida de Longo Prazo	xx
<u>Contas de Clientes</u>	xx	Notas de Crédito	xx
<u>Inventário</u>	xx	Despesas Acumuladas	xx
Pré-pagamentos	xx	Taxas	xx
Outros ativos correntes	xx	Outros passivos correntes	xx
Total de Ativos Correntes	xxx	Total de Passivos Correntes	xxx

Tabela 4: Exemplo do WCM num balanço, Strischek (2002)

A gestão eficiente destas variáveis destacadas, podem diminuir o NWC. Como exemplo, através de uma política mais agressiva nas contas de clientes, uma empresa não ficará tão dependente do financiamento de longo prazo (que é mais dispendioso do que o financiamento de curto prazo)¹ para financiar as suas operações.

Do ponto de vista do credor, os passivos correntes devem cobrir a maior parte do financiamento dos ativos correntes e a outra parte deve ser coberta pelo capital próprio dos shareholders.

Rehn (2012) dividiu o WCM em Working Capital Operacional (OWC) e Working Capital Financeiro (FWC). O primeiro é a parte que pode controlada e otimizada pela gestão das empresas e afeta as suas operações, esta parte é composta pelas contas de clientes, inventários e contas de fornecedores. O segundo é a parte que não está ligada diretamente às operações da empresa, mas são afetadas pelas decisões de financiamento.

Por um lado, quanto mais a empresa amarra os ativos ao WCM, mais ilíquida fica, isto significa que uma gestão eficiente do WCM possibilita à empresa investir no crescimento, pagar o financiamento de curto prazo e a reduzir os custos de investimento. Por outro lado, o problema situa-se na otimização do WCM, pois a empresa não pode reduzir ao máximo os prazos médios sem comprometer o volume de vendas, isto é, não se pode reduzir todo o crédito a clientes e para satisfazer a produção é necessário manter um determinado volume de inventários. Um ótimo nível de WCM é um onde existe um balanço entre risco e eficiência, Filbeck e Krueger (2005).

Segundo Rehn (2012), os recursos das empresas estão, normalmente, investidos em investimentos de capital, tal como, máquinas, equipamento e investimentos de curto prazo

¹As empresas têm que ter em conta o custo do capital e da dívida. Está na sua responsabilidade a decisão de optar por dívida de curto ou de longo prazo. A Média Ponderada de Custo de Capital é a forma de comparar o custo destes tipos de dívida.

(WCM). A forma como as empresas financiam estes investimentos, depende da sua estrutura de capital.

O NWC tem que ser financiado de alguma forma. No caso deste ser positivo (em que os ativos correntes superam os passivos correntes), é financiado com capital de longo prazo, tal como títulos ou empréstimos de longo-prazo, por outro lado, se este for negativo (os passivos correntes superam os ativos correntes), o NWC é financiado através de capital de curto prazo, que aumenta o custo do empréstimo significativamente.

O custo dos ativos que as empresas adquirem ao longo do tempo chama-se Requisitos de Capital Acumulado. Este capital, por norma, aumenta de forma irregular, tendo a ver com a natureza cíclica da maior parte dos negócios (ano a ano, mês a mês). Este capital pode ser financiado quer com financiamento de curto prazo, quer de longo prazo. No caso do financiamento de longo prazo não ser suficiente para cobrir o capital requerido, é necessário obter também financiamento de curto prazo para a empresa conseguir financiar as suas operações. Por outro lado, se o financiamento de longo prazo for superior ao capital requerido, a empresa terá um acréscimo de caixa. Isto ajuda a determinar o tipo de financiamento que a empresa, normalmente adquire através do seu balanço, Brealey et al. (2006).

Na figura 1, estão representadas 3 diferentes estratégias (A, B ou C) que as empresas podem tomar em relação ao Requisito de Capital Acumulado. Na medida em que as empresas crescem, também cresce o requisito de capital. No caso A, a linha indica uma estratégia em que a empresa tem excesso de caixa, que pode depois ser investido em aplicações de curto prazo. A linha B mostra uma estratégia onde a empresa dá crédito aos clientes durante metade do ano e, na outra metade, utiliza financiamento de curto prazo. A linha C mostra uma empresa que está em permanente necessidade de financiamento de curto prazo.

Esta figura mostra como o WCM afeta as decisões financeiras de uma empresa. Nalguns casos, as empresas que empatam capital nos ativos correntes, podem precisar de utilizar mais financiamento de longo prazo, do que uma empresa que consegue gerir a maturidade dos passivos de curto prazo com os ativos de curto prazo. Tendo conhecimento disto, é necessário que se tenha em conta que pode não existir uma estratégia ótima para todas as empresas, Brealey et al. (2006).

Isto significa que os ativos de longo prazo, tais como máquinas ou edifícios, são financiados com financiamento de longo prazo, enquanto que o WCM é financiado (o quanto possível) pelo financiamento de curto prazo. O resultado do NWC é, normalmente, positivo, isto implica um financiamento permanente. Segundo Brealey et al. (2006), a parte do NWC que excede os passivos correntes, é financiada com financiamento de longo prazo, tais como:




Figura 1: Requisitos de Capital Acumulado - Brealey et al. (2006)

capital próprio, empréstimos ou títulos.

Brealey et al. (2006) refere que para uma eficiente e eficaz do WCM, as empresas precisam de focar a sua atenção em quatro ativos de curto prazo:

- Contas de Clientes;
- Inventários;
- Caixa;
- Títulos de Curto Prazo.

O resultado das contas de clientes é o valor total de vendas a crédito. Dependendo dos termos de pagamento, as empresas podem receber o pagamento em diferentes prazos (dias, semanas ou até meses). Para se gerir estas contas, as empresas têm que estabelecer regras e políticas internas de vendas, atribuição e de coleta do crédito atribuído aos clientes. Se, por exemplo, a empresa melhorar a eficácia da coleta do crédito, pode melhorar o seu WCM significativamente. Por outro lado, se a política de atribuição e coleta de crédito for muito agressiva (restritiva), pode afetar o volume de vendas.

A gestão do inventário é um ativo corrente muito importante para as empresas. Dependendo do tipo de indústria, o inventário pode variar entre matéria-prima, produtos intermédios ou produtos finais. Gerir e otimizar o inventário é complicado e requer um balanceamento entre as vendas e o capital investido. No caso dos níveis de inventário serem

demasiado baixos, a empresa pode falhar a cobrir a procura caso esta aumente ou, não conseguir entregar os produtos a tempo. Se o valor de inventário for demasiado alto, significa que existe um empate de capital muito alto que poderia ter sido utilizado de forma mais eficiente. A tendência das empresas tem sido, nos últimos anos, de reduzir os níveis de inventário, Brealey et al. (2006).

Segundo o autor, as empresas americanas, nos anos 70, tinham aproximadamente 12% dos ativos investidos no inventário, face a 6% em 2006. O conceito que é utilizado regularmente é just-in-time - Os inventários são mantidos num nível mínimo e a estrutura de produção é otimizada para nunca se esgotarem.

A Caixa pode ser comparada aos inventários porque é também algo que a empresa precisa para funcionar. É normal as empresas terem grandes valores em caixa para controlar a liquidez. Isto gera o problema do custo de capital. Se este valor tivesse sido investido, ajudava a empresa a recuperar o custo do capital. As empresas também não podem investir todo o capital em títulos de curto prazo, pois iria aumentar o custo das transações. No entanto, conforme a dimensão da empresa, estes custos de capital tornam-se menores em relação ao retorno gerado pelos títulos.

Brealey et al. (2006) refere que muitas empresas utilizam uma estratégia chamada de “*sweeping*”, que as ajuda a ter maior rentabilidade nos balanços de caixa. Este “*sweeping*”, descreve que os balanços de caixa devem ser transferidos para OMMDA - Overnight Money Market Deposit Account - Contas de depósito que geram uma taxa de juro “*overnight*” - taxas “*swap*”. Existem outros tipos de títulos de curto prazo, tais como:

- Papel Comercial;
- Bonds;
- Fundos Mutualistas;
- Notas Corporativas;
- Hipotecas.

Rehn (2012) refere que, para uma empresa, é mais fácil de utilizar o Ciclo Operacional Líquido (NTC) do que o CCC. A diferença entre estas duas medidas, assenta no facto de que o Ciclo Operacional Líquido aplica os diferentes componentes do Ciclo de Conversão de Caixa como uma percentagem do volume de vendas, ou seja, através do cálculo do Ciclo Operacional Líquido, é possível estimar o financiamento que é necessário para uma projeção

do crescimento do volume de vendas. O NTC é uma medida importante para as empresas, pois mostra aos shareholders a capacidade da empresa em gerir o CCC.

Este autor refere que ao diminuir o Ciclo Operacional Líquido, será reduzida a necessidade de financiamento externo na gestão do Working Capital e reduz o custo de financiamento ao melhorar a performance financeira da empresa.

Segundo Shin e Soenen (1998), ao reduzir o número de dias do NTC, o valor do Cash Flow Líquido vai ser superior, o que significa mais valor para a empresa.

Shin e Soenen (1998) referem que um CCC mais longo pode indicar que as vendas de uma empresa estão a aumentar e que esta pode competir no mercado através de políticas de crédito aos clientes ou um maior volume de inventários. No entanto, um CCC mais longo pode diminuir a rentabilidade da empresa por aumentar o número de dias em que o valor das vendas não está a gerar juro, tal como no caso das contas de clientes. Se a empresa diminuir o CCC, o valor do Cash Flow Líquido irá aumentar, porque o valor das vendas retorna mais rapidamente para a empresa. De acordo com estes autores, um CCC mais curto contribui para uma maior liquidez e rentabilidade. Portanto, em vez das empresas decidirem-se pela rentabilidade ou pela liquidez, estas devem otimizar a relação das vendas e das finanças - otimizar o WCM.

Fórmula do Ciclo Operacional Líquido:

$$NTC = \frac{NS}{NWC} \div 365 \quad (1.6)$$

Onde:

NTC = Ciclo Operacional Líquido

NS = Vendas Líquidas

NWC = Working Capital Líquido (equação 1.5)

Exemplo de estimativa de financiamento - Rehn (2012):

- $NTC = 30$ dias;
- Projeção de Vendas = 1,000,000.00€.

$$RF = \frac{NTC}{360} \times SP \Leftrightarrow$$

(1.7)

$$\Leftrightarrow 83333.33 \approx \frac{30}{360} \times 1000000$$

Onde:

RF = Financiamento Necessário

NTC = Ciclo Operacional Líquido

Neste exemplo, uma determinada empresa com NTC de 30 dias, fez uma projeção do volume de vendas e espera que estas cresçam 1,000,000€ (um milhão de euros) no próximo período. Sabendo isto, a empresa pretende calcular qual o investimento necessário a realizar no WCM. Seguindo esta fórmula, a empresa terá que investir no WCM aproximadamente 83,000€ para suportar este aumento de vendas.

Hawawini et al. (1986) referem que o investimento nas operações da empresa podem ser definidos como WCM. Apesar de anteriormente ter sido referida a fórmula do NWC (equação 1.5) e que esta se traduz no valor que deverá ser investido em WCM, estes autores referem que a caixa, os títulos, operações a descoberto e a conta de pagamentos aos bancos não devem ser incluídas como para das operações da empresa. Daí, estes chegaram à fórmula do Working Capital Requerido (WCR).

$$WCR = NWC - NLB \quad (1.8)$$

Onde:

WCR = Working Capital Requerido

NWC = Working Capital Líquido

NLB = Saldo Líquido

$$NLB = C - STB \quad (1.9)$$

Onde:

NLB = Saldo Líquido

C = Caixa

STB = Títulos, operações a descoberto e notas de pagamento aos bancos

Os autores afirmam que o WCR é afetado por quatro componentes:

- Contas de Clientes;
- Inventários;
- Contas de Fornecedores;
- Outros Rendimentos e Outros Gastos.

E estes componentes são afetados pela tecnologia, eficiência operacional e volume de vendas.

As empresas utilizam diferentes técnicas para gerir o WCM e este depende de diversos fatores, como por exemplo do tipo de indústria onde a empresa se insere.

Gilbert e Reichert (1995) descobriram que 70% das empresas, num determinado tipo de indústria, utilizavam técnicas de gestão do WCM e, noutros tipos de indústria, todas as empresas utilizavam alguma técnica para o gerir.

Estes autores concluíram que a utilização de modelos de gestão do WCM, deve-se ao facto dos históricos níveis altos das taxas de juro e que as empresas não-financeiras investem apenas uma pequena parte dos seus ativos em títulos e as que o fazem, fazem-no, principalmente, por razões de liquidez. Os modelos das contas de clientes eram usados por quase 60% das empresas e o mesmo acontecia para os modelos de gestão de inventários. Os modelos de gestão de inventários começaram a ser mais frequentes durante os anos 80, muito provavelmente, como consequência do aparecimento do modelo just-in-time.

Richards e Laughlin (1980) referem que quanto mais extenso for o Ciclo de Conversão de Caixa, juntamente com um declínio dos inventários, menor será a liquidez. Por sua vez, quanto maior for o período de pagamento, juntamente com um declínio do prazo de recebimento, maior será a liquidez. Estes autores referem que muitas empresas, apesar das projeções de excelentes volumes de vendas e cash flow, não têm sucesso, precisamente pela falta

de gestão do Working Capital. É através da gestão do WCM que as empresas conseguem focar a sua atenção para os problemas do cash flow.

Segundo Shilling (1996), o objetivo das empresas é maximizar os lucros e para tal, estas precisam de investir em projetos com o maior Valor Atual Líquido (VAL). O WCM também gera rendimentos porém, estes são inferiores aos dos investimentos noutros projetos, sendo que é necessário encontrar um ponto ideal de investimento para um e para o outro, de forma a maximizar o lucro dos dois. Se não o fizerem, perderão capital nas contas de fornecedores, clientes e inventário.

Para este autor, a ferramenta mais dinâmica de gestão das contas de fornecedores, clientes e inventário é o Ciclo de Conversão de Caixa. E esta ferramenta ajuda as empresas a gerir a sua liquidez. Tal como outros autores referiram nos seus estudos, Shilling (1996), concluiu que quanto maior for o CCC, maior terá que ser o valor da liquidez para fazer face aos prazos de pagamento e quanto menor for o CCC, menor terá que ser essa liquidez. A liquidez torna-se importante nestes casos, pois representa capital que não está a ser otimizado para gerar o maior lucro possível. Dependendo da decisão das empresas, o CCC poderá ter que ser aumentado, devido a uma mudança na política de crédito a clientes, ou de novos prazos de pagamentos, mas a empresa terá que controlar estas contas de forma a dar retorno do investimento dos seus shareholders. O objetivo de gerir o CCC de forma eficiente e eficaz é gerar retorno com o excedente de caixa e diminuir os custos de financiamento, nomeadamente, os juros.

Soenen (1993) no seu estudo do WCM e da rentabilidade das empresas, obteve uma correlação negativa entre o Working Capital e a rentabilidade, sendo que, quanto menor o Ciclo de Conversão de Caixa, maior esta será e vice-versa.

Shin e Soenen (1998) fizeram um mega-estudo do Working Capital, em que analisaram 58 985 anos empresariais, para apurar a sua relação com a rentabilidade das empresas. As regressões feitas por estes autores mostraram uma relação significativa, negativa, entre o Ciclo Operacional Líquido e a rentabilidade.

Através de análises de Correlação de Pearson, estes autores encontraram relações negativas entre o NTC e a rentabilidade. Neste estudo foram utilizados como medidas da rentabilidade, o volume de vendas e o retorno sobre ativos. É através destes resultados que, Shin e Soenen (1998), confirmaram a hipótese que um Ciclo de Conversão de Caixa mais curto, gera mais rendimentos. Estes autores confirmaram, também, que os métodos tradicionais de gestão de liquidez são altamente deficientes, na medida em que pouco contribui para o rendimento das empresas.

O estudo indica que empresas com maior Ciclo Operacional Líquido têm uma maior alavancagem financeira, o que significa que estas empresas financiam as suas operações (particularmente o Working Capital) através de empréstimos.

No seu estudo, Shin e Soenen (1998) encontraram que existe, uma relação entre o rácio de liquidez geral e a rentabilidade das empresas, empresas com maior rentabilidade, têm uma maior liquidez.

$$P = OI + D \quad (1.10)$$

Onde:

P = Rentabilidade

OI = Resultado Operacional

D = Depreciações do Total de Ativos

$$CR = \frac{CA}{CL} \quad (1.11)$$

Onde:

CR = Liquidez Geral

CA = Ativos Correntes

CL = Passivos Correntes

No estudo do Working Capital de Deloof (2003), foram utilizados dados das empresas belgas, que foram obtidos através do Banco Nacional da Bélgica. Da análise foram retirados os dados das empresas de fornecimento de água e de energia, empresas financeiras (bancos e seguradoras) e empresas de outros serviços. Após esta filtragem de empresas, o autor contava com dados de 1009 empresas, dos anos 1992 a 1996 que resultou em 5045 anos empresariais para a sua análise. Este autor utilizou como fórmula de rentabilidade a seguinte fórmula:

$$P = \frac{S - COGS}{TA - FA} \quad (1.12)$$

Onde:

P = Rentabilidade

S = Vendas

$COGS$ = Custo dos Produtos Vendidos

TA = Total de Ativos

FA = Ativos Financeiros

O autor explica que, a razão de não ter utilizado outro método para obter a rentabilidade, baseia-se no facto de, para muitas empresas, os ativos financeiros, principalmente ações de outras empresas, comporem uma parte significativa do total de ativos.

No entanto, Deloof (2003) obteve uma relação negativa entre as contas de clientes e a rentabilidade das empresas, que não consegue explicar. Em estudos anteriores, nomeadamente os estudos de Schwartz (1974) e Emery (1984), apoiam a hipótese que empresas com contas de clientes mais elevadas são mais rentáveis do que empresas com contas de clientes menos elevadas. A ideia por detrás desta hipótese resume-se que as empresas com contas de clientes mais elevadas, não estão apertadas em termos de fundo de maneo, dando assim, aos seus clientes, maiores prazos de pagamento do que empresas com menor fundo de maneo.

Deloof (2003) referiu o estudo não publicado de Brealey et al. (2006) sobre créditos comerciais na Europa, em que este descobriu que 75% das empresas belgas ofereciam um desconto de pronto-pagamento e que esse desconto era em média 3%. Deloof (2003) refere que este aumento do Prazo Médio de Recebimento pode aumentar a rentabilidade porque afeta o volume de vendas, no entanto, quanto maior a diferença entre o Prazo Médio de Recebimento e o Prazo Médio de Pagamento, maior é o investimento no Ciclo de Conversão de Caixa. Este autor aponta também para o problema das empresas necessitarem de aumentar o DPO para equilibrarem o CCC.

Tal como neste estudo, o estudo de Lazaridis (2006) e de Shin e Soenen (1998) tiveram resultados que mostram que existe uma correlação negativa entre o Prazo Médio de Pagamento e a rentabilidade, que sugere que empresas menos rentáveis têm um maior prazo médio de pagamento. Existe também uma relação negativa entre o Prazo Médio de Rotação de Inventário e a rentabilidade, que sugere que existe uma falha de gestão dos inventários pois, esse capital poderia estar aplicado e a gerar rendimento e que poderá haver uma quebra na procura dos produtos das empresas.

Estes autores, concluíram que um gestor pode criar mais valor para os shareholders através de uma otimização dos níveis de inventário, contas de clientes e contas de fornecedores,

assim reduzindo o Ciclo de Conversão de Caixa.

Rehn (2012), no seu estudo do Working Capital das empresas finlandesas e suecas, esperou confirmar as seguintes hipóteses:

- Uma gestão eficiente do WCM afeta a rentabilidade das empresas;
- Existe diferenças no WCM das empresas dos dois países;
- Os resultados do impacto do WCM são diferentes para diferentes tipos de indústrias;
- Empresas com menor Prazo Médio de Pagamento são mais rentáveis.

Os dados estudados neste estudo são relativos a empresas que cumprem estes 4 requisitos:

- Empresas Públicas;
- Empresas da Finlândia ou da Suíça;
- Empresas de todas as indústrias exceto financeiras e serviços;
- Empresas dos anos 2002 a 2010.

Todos os dados das empresas que não se enquadraram nestes 4 requisitos, foram retirados do estudo. Este autor utilizou, como medida do Working Capital, o Ciclo de Conversão de Caixa e, como medida da rentabilidade, o rácio de resultado operacional bruto.

$$GOPR = \frac{S - COGS + DA}{TA - FA} \quad (1.13)$$

Onde:

GOPR = Rácio de Resultado Operacional Bruto

S = Vendas

COGS = Custo dos Produtos Vendidos

DA = Depreciações e Amortizações

TA = Total de Ativos

FA = Ativos Financeiros

Rehn (2012) analisou 1789 anos empresariais e 13 tipos de indústrias. Este autor observou os efeitos da crise de 2007 nas empresas e concluiu que nesse ano houve um aumento do Ciclo de Conversão de Caixa pois, os clientes levaram mais tempo para pagar e as empresas permaneceram com grande volume de inventário, derivado à diminuição do volume de vendas.

Após a crise de 2007, observou-se uma queda acentuada nos níveis de CCC, o autor refere que isto poderá ser devido a uma melhor gestão do Working Capital ou um aumento do volume de vendas. O autor refere que se for considerado que o aumento das vendas está, normalmente, associado ao WCM, poderá ser assumido que as empresas melhoraram a sua gestão do WCM à procura de um aumento de liquidez.

O autor dividiu cada indústria em quatro quartis, cada quartil foi definido conforme um nível de rentabilidade como fator, ou seja, os quatro quartis representam um nível de rentabilidade, em que o quartil 1, representa as empresas com menos rentabilidade e o quartil 4, as com mais.

Ciclo Operacional Líquido e Working Capital por quartil			
		NTC	WCM
Q1 - Mais pequeno (25%)	Média	86,0520	89,3534
	Número de dados	430	427
Q2 (25% - 50%)	Média	74,1358	82,3761
	Número de dados	446	445
Q3 (50% - 75%)	Média	78,2191	89,3362
	Número de dados	445	443
Q4 - Mais alto (25%)	Média	68,0074	77,9652
	Número de dados	452	443

Tabela 5: Tabela de resultados por quartil do estudo de Rehn (2012)

Através desta tabela vemos que, apesar de algumas discrepâncias, nomeadamente o quartil 3, as empresas mais rentáveis têm um menor número de dias de Ciclo de Conversão de Caixa.

O autor mostrou que não existe uma diferença significativa entre as empresas finlandesas e as empresas suecas e que estes valores indicam como a economia global provoca uma pressão igual para os dois países e que estes tentam maximizar o valor das empresas para os shareholders através de uma gestão eficiente do Ciclo de Conversão de Caixa.

Rehn (2012) refere que uma empresa que opera no retalho, tem uma gestão do Working Capital diferente de uma empresa que opera na manufatura. Por isso, o autor fez uma análise por tipo de indústria, para se apurar, com a maior precisão possível, a relação entre o WCM

e a rentabilidade das empresas.

Tabela de Dados			
		Média	Desvio-Padrão
CCC	Finlândia	84,3090	3,74740
	Suécia	85,0036	2,47213
NTC	Finlândia	76,5302	1,93394
	Suécia	76,4586	1,70874
Prazo Médio de Recebimento	Finlândia	56,18	1,449
	Suécia	57,38	0,922
Prazo Médio de Pagamento	Finlândia	67,63	2,054
	Suécia	61,53	1,598
Prazo Médio de Rotação de Inventário	Finlândia	96,2638	2,84763
	Suécia	90,8281	2,19857

Tabela 6: Tabela de dados das empresas finlandesas e suecas do estudo de Rehn (2012)

Os resultados deste estudo mostraram que, na maior parte das casos estudados, o CCC está negativamente relacionado com a rentabilidade das empresas. Um dos casos em que acontece o contrário é o das empresas de fabrico de químicos, borracha, plástico e materiais não metálicos, em que, conforme o Ciclo de Conversão de Caixa aumenta, maior é a sua rentabilidade. A industria mais afetada pela gestão do WCM é a de outros serviços.

Das hipóteses propostas neste estudo, a primeira (a eficiência da gestão do WCM afeta a rentabilidade das empresas), foi confirmada. A segunda hipótese, a existência de diferenças entre as empresas da Finlândia e da Suécia, não foi confirmada. Os dados obtidos neste estudo não se mostraram relevantes para apurar uma diferença das empresas destes dois países. Os resultados obtidos, apontam para uma diferença entre as diferentes indústrias, mas não existe significância estatística suficiente para confirmar/rejeitar a terceira hipótese, a existência de diferenças entre as empresas de diferentes indústrias. E a hipótese 4, empresas com menor Prazo Médio de Pagamento são mais rentáveis, não foi confirmada.

Noutro estudo das empresas finlandesas dos anos 2003-2007, feito por Zhang (2011), foi, também, encontrada uma reação negativa entre o CCC e a rentabilidade das empresas. Neste estudo, o autor propôs a hipótese das empresas com maior Prazo Médio de Pagamento serem menos rentáveis, mas esta hipótese não foi confirmada.

Segundo o autor, através da gestão dos Prazo Médio de Recebimento, Prazo Médio de Rotação de Inventário e Prazo Médio de Pagamento, as empresas conseguem diminuir o Ciclo de Conversão de Caixa e assim gerar maior rendimento. No entanto, a gestão eficiente do Working Capital expõe as empresas a um baixo nível de inventário e um maior valor de empréstimos para equilibrar a falta de rendimento das contas de clientes.

Este autor, através dos resultados, observou que, ao contrário do que propunha nas suas hipóteses, as empresas com maior eficiência de gestão do WCM não têm maior reserva de caixa. O estudo mostrou que estas empresas têm uma diminuição da reserva de caixa, na medida em que otimizam o WCM.

Russo (2013) estudou as pequenas e médias empresas portuguesas, dos anos 2009 a 2011. Os dados consistiam em 1191 empresas, em que 81.88% das empresas eram de tamanho médio, 17.20% de tamanho pequeno e 0.92% eram micro empresas.

Ao contrário do estudo de Serrasqueiro (2014), Russo (2013) obteve uma fraca relação negativa entre o Ciclo de Conversão de Caixa e a rentabilidade das empresas. Este autor obteve resultados que mostram que as empresas mais pequenas são mais rentáveis. A correlação de Pearson da dimensão da empresa com a rentabilidade tem um valor de -0.4463.

Russo (2013) sugere que as pequenas e médias empresas portuguesas têm uma melhor gestão do Working Capital quando têm um maior cash-flow. Isto é explicado pelo facto da gestão do WCM otimizar os prazos médios, nomeadamente o aumento do Prazo Médio de Pagamento. O autor refere que empresas com maior liquidez têm uma melhor gestão do WCM.

Raheman e Nasr (2007) utilizaram no seu estudo a correlação de Pearson e obtiveram o resultado de uma forte relação entre o Ciclo de Conversão de Caixa e a rentabilidade das empresas. O estudo foi realizado com base em 94 empresas paquistanesas durante um período de 6 anos, ou seja, 564 anos empresariais. Estes autores referem que um CCC mais alto leva a uma diminuição da rentabilidade das empresas e que, para os gestores das empresas aumentarem o valor para os shareholders, o CCC deve ser reduzido até ao mínimo valor possível.

Estes autores verificaram uma relação negativa significativa entre a dívida e a rentabilidade. Nas empresas paquistanesas, o rácio de liquidez geral mostra-se o rácio mais importante sobre a liquidez que afeta a sua rentabilidade, pois as empresas que têm maior dívida são, normalmente, empresas menos rentáveis. No entanto, Raheman e Nasr (2007) concluíram que o Ciclo de Conversão de Caixa é mais importante para a rentabilidade das empresas do que a sua liquidez, pois este fator afeta tanto um como o outro. Por outro lado, a dimensão da empresa tem um impacto positivo na rentabilidade, sendo que empresas maiores têm maior rentabilidade.

No artigo de Gill et al. (2010), os autores analisaram o impacto do WCM na rentabilidade de 88 empresas americanas listadas na Bolsa de Valores de Nova Iorque durante um período

de 3 anos, 2005 (inclusive) a 2007, que resultou em 264 observações. Tal como nos estudos de Deloof (2003) e de Lazaridis (2006), utilizaram o Ciclo de Conversão de Caixa como método de avaliação do WCM e utilizaram como método de avaliação da rentabilidade o Resultado Operacional Bruto, definido pela fórmula 1.12.

Os autores optaram por esta fórmula em vez do Resultado Operacional Bruto (EBITDA), pois o objetivo era associar a rentabilidade com o sucesso operacional das empresas. Para mais, Raheman e Nasr (2007) pretendiam retirar qualquer atividade financeira das atividades das empresas que pudesse influenciar a rentabilidade.

Neste estudo, os autores obtiveram uma relação positiva entre o CCC e a rentabilidade e uma relação negativa entre o Prazo Médio de Recebimento e a rentabilidade, o que sugere que empresas com uma política de crédito aos clientes mais alargada são menos rentáveis. No entanto, os autores referem que os resultados deste estudo só têm como base empresas de manufatura de uma forma generalizada e que o tamanho dos dados é pequeno.

Padachi (2006) estudou 58 empresas mauritanas, do período de 1997 a 2003, que resultou em 348 anos empresariais. O autor calculou a correlação entre a rentabilidade das empresas e do WCM e esta mostrou-se positiva, ou seja, as empresas mais rentáveis têm um maior número de dias no Ciclo de Conversão de Caixa. Por outro lado, foi observada uma correlação negativa mais significativa com o Prazo Médio de Recebimento e o Prazo Médio de Pagamento.

Este autor concluiu que a gestão do WCM é importante para a saúde financeira das empresas e que, nos resultados, as empresas mauritanas mostraram-se mais rentáveis conforme menor o número de dias de inventário, contas de clientes e contas de fornecedores.

1.1 Conceito de Ciclo de Conversão de Caixa

Segundo Deloof (2003), o Ciclo de Conversão de Caixa é simplesmente um resultado entre o Prazo Médio de Recebimento, Prazo Médio de Rotação de Inventário e o Prazo Médio de Pagamento. Padachi (2006) refere que este resultado é uma medida para mostrar a diferença temporal entre os diferentes prazos. A gestão do dia-a-dia centra-se nos ativos e passivos de curto prazo que têm um impacto significativo na rentabilidade das empresas, Plant (2007). Empresas com perspetivas de longo prazo e consistentes financeiramente não se mantêm solventes sem uma boa gestão da liquidez.

Em diferentes estudos, pode observar-se que são utilizadas diferentes fórmulas para men-

surar o Working Capital. No entanto, a fórmula mais utilizada pelos diversos autores é a do Ciclo de Conversão de Caixa.

$$CCC = CO - DPO \quad (1.14)$$

Onde:

CCC = Ciclo de Conversão de Caixa

OC = OC (equação 3.2)

DPO = Prazo Médio de Pagamento (equação 3.3)

Plant (2007) e Prat (2003) definiram o *Working Capital* baseado nos ativos e passivos correntes:

$$WCM = CA - CL \quad (1.15)$$

Onde:

WC = *Working Capital*

CA = Ativos Correntes

CL = Passivos Correntes

$$CA = C + R + I \quad (1.16)$$

Onde:

CA = Ativos Correntes

C = Caixa

R = Contas de Clientes

I = Inventários

$$CL = P + B + L \quad (1.17)$$

Onde:

CL = Passivo Corrente

P = Contas de Fornecedores

B = Empréstimos de Curto Prazo

L = Passivos Acumulados

1.2 Componentes do Ciclo de Conversão de Caixa

O Ciclo de Conversão de Caixa é uma ferramenta fundamental das empresas e baseia-se em três prazos de grande importância para a gestão de uma empresa, o Prazo Médio de Recebimento, Prazo Médio de Rotação de Inventário e o Prazo Médio de Pagamento.

$$OC = DSO + DIO \quad (1.18)$$

Onde:

OC = Ciclo Operacional

DSO = Prazo Médio de Recebimento (equação 3.5)

DIO = Prazo Médio de Rotação de Inventário (equação 3.4)

O Prazo Médio de Pagamento representa um prazo que as empresas têm para cumprir as suas obrigações com os fornecedores. Este prazo corresponde ao tempo desde o fornecimento das matérias-primas até ao seu pagamento. À medida que a dívida aos fornecedores aumenta, este prazo também aumenta. As empresas tentam aumentar este prazo em vez de pedirem empréstimos a instituições financeiras porque têm um custo inferior e com esta oportunidade financeira investem o capital noutras atividades de forma a obter maiores rendimentos, Serrasqueiro (2014).

$$DPO = \frac{AP}{P} \times 365 \quad (1.19)$$

Onde:

DPO = Prazo Médio de Pagamento

AP = Contas de Fornecedores

P = Compras

O inventário é um ativo importante das empresas. Dependendo da indústria onde a empresa se insere, o inventário pode consistir em matéria-prima, produtos intermédios ou produtos finais. A tendência dos últimos anos é que o valor de inventário diminua, Brealey et al. (2006). Segundo Serrasqueiro (2014), os inventários são ativos que podem ser convertidos em capital no curto prazo (vendas). Estes têm custos associados que são, normalmente, custos de armazenagem e custos de gestão. O custo de armazenamento é um custo de natureza física, como por exemplo o custo de renda de armazém, o custo de arcas frigoríficas, etc. O custo de gestão está relacionado com o controlo e coordenação do armazenamento dos inventários.

Um aumento no volume de inventário causa um aumento no Prazo Médio de Rotação de Inventário. As empresas, por norma, tentam diminuir o volume de inventário o quanto possível, mas por vezes, derivado do tipo de negócio, os produtos têm que ser retidos por um determinado período de tempo até serem acabados ou atingirem a maturidade necessária para serem vendidos, Serrasqueiro (2014).

$$DIO = \frac{I}{P} \times 365 \quad (1.20)$$

Onde:

DIO = Prazo Médio de Rotação de Inventário

I = Inventários

P = Compras

O Prazo Médio de Recebimento representa o número de dias médio que os clientes demoram a concluir o pagamento da aquisição de um bem ou serviço. As empresas quando definem uma política de crédito aos clientes estão a influenciar diretamente este prazo. Se uma empresa optar por uma política de crédito mais restritiva, estará a tentar diminuir este prazo, Rehn (2012). Segundo Brealey et al. (2006), se uma empresa for demasiado restritiva na sua política de crédito poderá, ao invés de diminuir o prazo de pagamento, diminuir o volume de vendas. Portanto, as empresas terão que analisar a política de crédito que pretendem oferecer aos seus clientes, de forma a maximizar o volume de vendas. Serrasqueiro

(2014) refere que quando as empresas estão a permitir aos seus clientes pagar mais tarde, estão a emprestar capital aos clientes a um custo inferior ao que estes teriam com outro tipo de credor. Isto é para dizer que as empresas fazem melhores avaliações de crédito do que as instituições financeiras.

Preve e Sarria-Allende (2010) referem que o facto das empresas que não são financeiras, estarem a fazer negócio com crédito é uma situação interessante. Estes autores ponderam na razão das empresas darem crédito aos seus clientes e a outras empresas e o porquê dos clientes estarem dispostos a aceitar esse financiamento de instituições não financeiras. Os autores explicam que os termos destes créditos variam de indústria para indústria, dependendo da competitividade e das condições monetárias do mercado. Por exemplo, em mercados muito competitivos, as políticas de crédito a clientes são mais agressivas para aumentar o volume de vendas.

$$DSO = \frac{AR}{S} \times 365 \quad (1.21)$$

Onde:

DSO = Prazo Médio de Recebimento

AR = Contas de Clientes

S = Vendas

Na figura 2, pode observar-se que o Ciclo de Conversão de Caixa corresponde à diferença do tempo entre o pagamento aos fornecedores (compra de matéria-prima) e o recebimento das vendas (contas de clientes).

Um CCC maior significa que existe um maior prazo em que a empresa não recebe o valor das vendas e que tem que cumprir as suas obrigações para com os fornecedores. Se este prazo for muito alargado, a empresa poderá ter que recorrer a financiamento externo para poder pagar aos seus fornecedores. Por outro lado, se o prazo for muito curto, a empresa poderá pagar diretamente aos fornecedores com as receitas das vendas, mas um prazo muito curto de recebimento (política de crédito a clientes muito restritiva), pode afetar o volume de vendas. É necessário que as empresas otimizem o Ciclo de Conversão de Caixa de forma a maximizar as vendas e a fazerem face às obrigações com o menor custo possível.

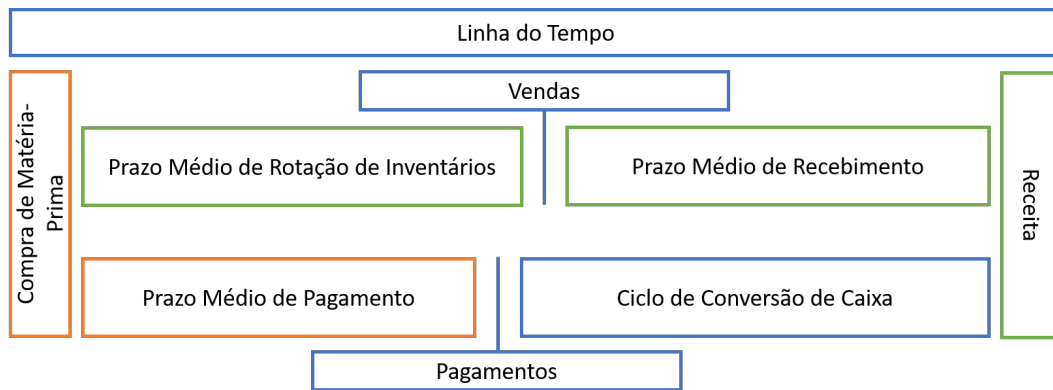


Figura 2: Ciclo de Conversão de Caixa - Adaptado do modelo de Richards e Laughlin (1980)

1.3 Rentabilidade das empresas

Preve e Sarria-Allende (2010) referem que a maioria das empresas têm na sua origem um investidor que está disposto a investir o seu capital em troca de um retorno do investimento (Return On Investment - ROI). Quanto maior o risco do investimento, maior será o retorno esperado.

O capital que o investidor utiliza para financiar a empresa chama-se Capital Inicial. Este capital é investido nos ativos da empresa e pode consistir em propriedades, máquinas, inventário, caixa e até financiamento dos clientes. Em alguns casos, o investidor toma todas as decisões da empresa - acontece principalmente em pequenas empresas. Noutros casos, existe um conselho de administradores que tomam essas decisões. Todas as decisões tomadas têm como objetivo chegar ao retorno esperado pelos investidores e para isso, é necessário utilizar o capital investido na produção de produtos ou serviços que serão, depois, vendidos aos clientes da empresa, Preve e Sarria-Allende (2010).

As empresas, no seu processo de produção, têm custos, como por exemplo, custos de matérias-primas, custos com o pessoal, inventários, distribuição e impostos. O que sobra dos resultados das vendas menos todos os custos, chama-se lucro. O lucro é uma medida básica para os investidores estimarem o retorno do investimento.

No fim de cada ano as empresas têm como obrigação mostrar os seus resultados através do balanço e da demonstração de resultados. O balanço mostra a situação financeira de uma empresa num determinado período. O balanço mostra os ativos, os passivos e o capital próprio de uma empresa sendo que:

$$AC + ANC = PC + PNC + CP \quad (1.22)$$

Onde:

AC = Ativos Correntes

ANC = Ativos Não Correntes

PC = Passivos Correntes

PNC = Passivos Não Correntes

CP = Capital Próprio

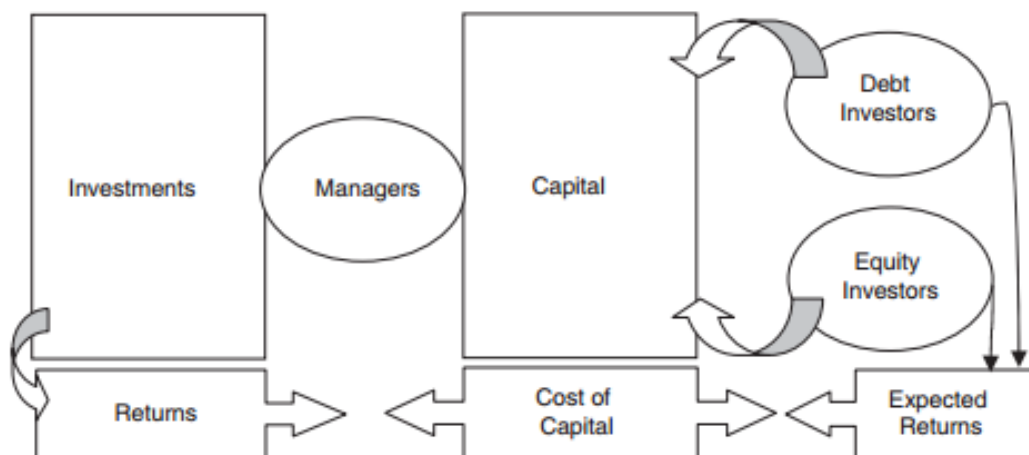


Figura 3: Ciclo das finanças empresariais - Preve e Sarria-Allende (2010)

Por outro lado, a demonstração de resultado representa a situação operacional da empresa. Este mostra o volume de vendas, o custo dessas vendas (custos com pessoal, matérias-primas, etc.), amortizações, depreciações e imparidades. Tal como o balanço, a demonstração de resultados é normalmente calculada em prazos anuais que é utilizado, principalmente, para fins legais, mas é possível obter balanços e demonstrações de resultados semanalmente, mensalmente e trimestralmente para se poder analisar a empresa ao longo do tempo.

O primeiro item numa demonstração de resultados é as vendas, que representa o somatório do valor de todos os produtos vendidos no período. No entanto, este valor de vendas não representa o pagamento dos produtos, pois pode ter sido atribuído crédito aos clientes. Após as vendas, vêm os custos dessas vendas, onde são contabilizados as matérias consumidas na produção dos produtos, custos de pessoal, outros fornecimentos e imparidades. O EBITDA é o Resultado Operacional Bruto e representa o resultado antes de impostos, taxas, amortizações e depreciações. Após as depreciações e as amortizações, obtém-se o Resultado Operacional Líquido (EBIT). No final, após todos os impostos e taxas, obtém-se o Resultado Líquido do Período (RLP).

Preve e Sarria-Allende (2010) afirmam que existe uma relação entre o balanço e a demonstração de resultados, quando acontece uma alteração num, o outro também é afetado.

Em Portugal, o atual sistema contabilístico é o SNC (Sistema de Normalização Contabilística) e uma demonstração de resultados publicada sob este sistema tem que seguir o modelo representado na tabela 40 nos anexos.

Existem duas formas de aumentar a rentabilidade de uma empresa: aumentando as vendas e diminuindo os custos. Atingir um número de vendas mais elevado representa um custo de investimento para empresa, seja em publicidade, aumento de crédito aos clientes ou aumento do prazo de recebimento. Diminuir os custos de uma empresa requer uma gestão meticulosa do processo produtivo. A diminuição dos custos pode passar por uma melhoria no processo produtivo, melhoria dos equipamentos ou redução dos recursos humanos. No entanto, ambos processos representam custos, uma forma de não ter tantos custos, é uma gestão mais eficiente das diferentes variáveis do Ciclo de Conversão de Caixa. No estudo do Working Capital de Uyar (2009) sobre as empresas turcas, o autor conclui que existe uma relação negativa entre o CCC e a rentabilidade das empresas, ou seja, quanto menor for o valor de CCC, maior será a rentabilidade.

Capítulo II

Caracterização mundial do setor vitivinícola

Segundo Cholette et al. (2005), há duas décadas o mercado da vitivinicultura encontrava-se fragmentado, os produtores estavam isolados e operavam apenas no mercado interno. No entanto, durante este período o mercado reduziu as barreiras do comércio mundial, diminuiu as tarifas e promoveu aos produtores novas formas de vender os produtos fora de uma região limitada, ou seja, estes produtores, ao invés de venderem apenas no mercado interno, passaram a interagir num mercado aberto e sujeitos a concorrência por parte de outros produtores. Em 2001, os produtores do velho mundo representavam 73% do mercado mundial do vinho, enquanto os produtores do novo mundo representavam apenas 23%. Os restantes 6% pertencem a outros países dispersos.

O setor vitivinícola tem-se tornado num mercado cada vez mais globalizado e tem sofrido mudanças ao longo do tempo. A crise financeira de 2007 foi um fator importante para as alterações do mercado da vitivinicultura global. Os países tradicionalmente consumidores de vinho viram a sua riqueza económica diminuir e por consequência o consumo interno de vinho diminuiu. Por outro lado, países que não consumiam muito, começaram a consumir e a produzir.

Para Thorpe (2009), o crescimento da produção de vinho nos países do novo mundo forçou os países do velho mundo a tornarem-se mais competitivos para atingirem os novos mercados. Algumas empresas destes países formaram parcerias para fazer face ao mercado que se torna cada vez mais segmentado e existe a tendência de aumentar o *marketing* focado a um número mais alargado de consumidores nos países desenvolvidos e criar raízes em países que tradicionalmente não consumiam vinho e que estão em desenvolvimento. Atualmente, a China está a entrar no mercado da vitivinicultura e está a ter alguma influência no mercado mundial. Para além da China, este autor refere também a Roménia.

Segundo Thorpe (2009), os maiores produtores que se enquadram no novo mundo são:

- Estados Unidos da América;
- Austrália;
- Chile;
- África do Sul;
- Nova Zelândia;
- Argentina.

Os países que se enquadram no velho mundo são:

- França;
- Itália;
- Espanha;
- Portugal;
- Alemanha.

Para Anderson e Wittwer (2013), o rápido crescimento económico e a rápida industrialização da China, aumentou o rendimento da classe média e esta fez aumentar a procura do mercado vitivinícola. Este facto, fez com que se aumentasse as áreas de produção de vinho na China, mas mesmo assim, não chega para cobrir a procura interna.

Anderson e Wittwer (2017) refere que o mercado mundial irá sofrer mais alterações devido ao BREXIT. Segundo este autor, o Reino Unido é fundamental no círculo do vinho, pois representa a maior cota de importação de vinho do mercado mundial. Este autor refere que as cotas atuais são muito diferentes do que eram em 1995, quando o novo mundo começava a expandir as suas exportações. No entanto, estas mudanças não vêm sem precedentes, isto é, as primeiras mudanças já tinham ocorrido com acordos preferências com Portugal (tratado de Methuen 1703), França (tratado de Cobden-Chevalier 1860) e os países da Comunidade das Nações (*Commonwealth of Nations*).

2.1 Produção

Thorpe (2009) refere que a produção global entrou em declínio a partir dos anos 80 e que começou a estabilizar recentemente. A produção dos países do velho mundo tem

variado devido às condições climáticas e os países do novo mundo têm aumentado a sua produção devido à consolidação industrial, aumento das áreas de plantação das vinhas e melhor tecnologia.

Segundo International Organization of Vine and Wine (2017), no relatório anual da situação da vitivinicultura mundial, os cinco países com maior área coberta por vinhas são a Espanha, a China, a França, a Itália e a Turquia. Estes países representam 50% da área mundial coberta por vinhas, sendo que a Espanha representa 14%, a China representa 11%, a França representa 10%, a Itália representa 9% e a Turquia representa 7%. A área total destinada à vitivinicultura em 2016 era de 7.5 milhões de hectares. Portugal tem uma área de cultivo equiparada à Roménia, 190 mil hectares e 191 mil hectares respetivamente. De 2012 a 2016, o país que teve maior crescimento da área de cultivo foi a China, que aumentou a área em 141 mil hectares e o país que teve maior diminuição da sua área foi Portugal, que diminuiu a área de cultivo em 41 mil hectares.

Variação da área sobre vinhas dos principais países em milhares de hectares			
País	2012	2016	Variação
Espanha	969	975	6
China	706	847	141
França	792	785	-7
Itália	713	690	-22
Turquia	497	480	-17
EUA	430	443	13
Argentina	222	224	2
Irão	226	223	-3
Chile	206	214	8
Roménia	196	191	-1
Portugal	231	190	-41

Tabela 7: Variação da área sobre vinhas dos principais países - Fonte: International Organization of Vine and Wine (2017)

International Organization of Vine and Wine (2017) mostra que a produção da Europa representa 39% da produção mundial, que a produção da Ásia representa 34% e que a produção da América representa 18%. Só em termos de produção de uvas (destinadas para todos os usos), a China (14.5 milhões de toneladas) tem quase o dobro da produção do país em segundo lugar - a Itália (7.9 milhões de toneladas). No entanto, apenas 12% da produção se destina a vinhas para produção de vinho, 83% a produção de uvas frescas e 6% de uvas secas. Por outro lado, a Itália dedica 85% da sua produção para o vinho e 15% para uvas frescas. Na escala global, a produção de uvas destinadas à produção de vinho é de 47%.

Produção de uvas em milhões de toneladas				
País	Produção	Uvas frescas	Uvas secas	Uvas para vinho
China	14.5	83%	6%	12%
Itália	9.9	15%	0%	85%
EUA	7.1	40%	18%	42%
França	6.4	1%	0%	99%
Espanha	6.0	5%	0%	87%
Mundo	75.8	36%	8%	47%

Tabela 8: Produção de uvas dos principais países - Fonte: International Organization of Vine and Wine (2017)

Produção de vinho em milhões de hectolitros			
País	2016	Variação em Volume	Variação em %
Itália	50.9	0.9	2%
França	43.5	-3.5	-7%
Espanha	39.3	1.7	4%
EUA	23.9	2.2	10%
Austrália	13.0	1.1	9%
China	11.4	-0.1	-1%
África do Sul	10.5	-0.7	-6%
Chile	10.1	-2.7	-21%
Argentina	9.4	-3.9	-29%
Alemanha	9.0	0.1	1%
Portugal	6.0	-1.0	-15%
Mundo	267	-9	-3%

Tabela 9: Produção de uvas dos principais países - Fonte: International Organization of Vine and Wine (2017)

Segundo os dados publicados por International Organization of Vine and Wine (2018), a área sobre vinhas está numa fase de declínio. De 2015 para 2016, a área foi reduzida em cerca de 22,000 hectares e em 2017 o valor era semelhante, sendo que a área total sobre vinhas prevista seria de 7.6 milhões de hectares. Este relatório mostra também que a produção mundial de vinho tem diminuído.

A produção prevista na Europa para 2017 mostra uma diminuição de 14.6% face ao ano de 2016. Para os principais produtores europeus, Itália, França, Espanha e Alemanha, a diminuição prevista é de 17%, 19%, 20% e 15% respetivamente. Estes valores são o resultado das condições climáticas adversas registadas para estes países e estes valores são ainda mais baixos do que os valores registados em 2012 que eram considerados os mais baixos. Para o novo mundo os valores estão a estabilizar após o impacto do “El Niño” em 2016. Para o ano de 2017 estava previsto um retorno dos valores de produção e que o Brasil

iria voltar à normalidade. No entanto, para o Chile a produção iria reduzir novamente. Para Portugal, a produção prevista para 2017 aumenta em 10% face à produção de 2016, sendo assim 6.6 milhões de hectolitros.




Figura 4: Produção mundial de vinho. Fonte: International Organization of Vine and Wine (2018)

2.2 Exportação

Em termos de exportação os países que mais se destacam a nível mundial são a Espanha, a Itália, a França e o Chile. O Chile é o país com mais crescimento do volume de exportações, que aumentou 21.3% de 2012 até 2016. A tabela 10 mostra a variação e o volume que foi exportado em 2016 pelos países mais relevantes do setor vitivinícola.

Na figura 5 pode-se comparar a cota de produção na produção mundial de vinho o velho mundo e o novo mundo. Esta figura mostra que o novo mundo surge nos anos 90 e que tinha aproximadamente metade da produção do velho mundo. No entanto, em 2016, o novo mundo representa mais de 35% da produção mundial de vinho.

2.3 Importação

Dos países importadores de vinho na tabela 11, os primeiros 5 (Alemanha, Reino Unido, EUA, França e China) representam mais de 50% de todas as importações (55.3 mhl) com um valor de 14.4 mil milhões de euros em 2017. No entanto, International Organization of

Maiores exportadores de vinho				
País	Volume (mhl)		Valor (m €)	
	2016	2017	2016	2017
Espanha	24.4	22.1	2,649	2,814
Itália	20.6	21.4	5,582	5,873
França	14.4	15.4	8,263	8,989
Chile	9.1	9.8	1,668	1,741
Austrália	7.5	8.0	1,543	1,727
África do Sul	4.3	4.5	602	583
Alemanha	3.8	3.8	936	926
EUA	3.8	3.3	1,415	1,280
Portugal	2.8	3.0	723	752
Nova Zelândia	2.1	2.5	1,017	1,054
Argentina	2.6	2.2	739	713

Tabela 10: Exportação de vinho dos principais países (volume em mhl e valor em milhões de €) - Fonte: International Organization of Vine and Wine (2018)




Figura 5: Produção mundial de vinho. Fonte: International Organization of Vine and Wine (2018)

Vine and Wine (2018) refere que não se sabe quais serão as consequências do BREXIT na indústria do vinho. Em 2017 a França teve uma importação 0.4% superior a 2016 e segundo este relatório, mostra que existe um défice estrutural em relação aos vinhos do nível de entrada. A China teve um valor de importação em € muito próximo ao da Alemanha, isto deve-se ao grande volume de importação de vinho engarrafado. A China foi o país que mais contribuiu, em termos de volume, para o crescimento do setor vitivinícola em 2017. Segundo International Organization of Vine and Wine (2018), a Holanda teve um aumento significativo de importação face a 2016. Em 2017, a Holanda teve um aumento de 10.9% em termos de volume e 16.2% em termos de valor. Na figura 6 é possível verificar o tipo de

vinho mais importado para cada um dos países mais importadores do ano de 2017.

Maiores importadores de vinho				
País	Volume (mhl)		Valor (m €)	
	2016	2017	2016	2017
Alemanha	15.2	15.2	2,510	2,469
Reino Unido	13.5	13.2	3,499	3,453
EUA	11.1	11.8	5,009	5,190
França	7.6	7.6	741	812
China	6.4	7.5	2,143	2,458
Rússia	4.0	4.5	662	878
Holanda	4.0	4.4	980	1,139
Canadá	4.2	4.1	1,604	1,653
Bélgica	3.1	3.1	902	897
Japão	2.7	2.6	1,343	1,388

Tabela 11: Importação de vinho dos principais países (volume em mhl e valor em milhões de €) - Fonte: International Organization of Vine and Wine (2018)

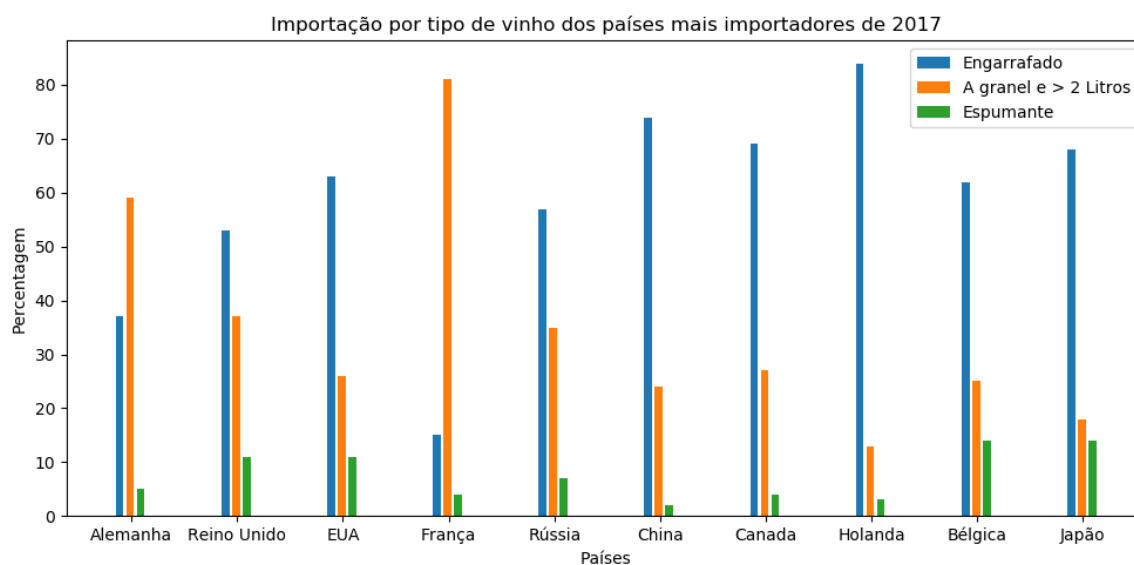


Figura 6: Importação por tipo de vinho dos países mais importadores do ano de 2017. Fonte: International Organization of Vine and Wine (2018)

2.4 Consumo

Thorpe (2009) refere que o consumo de vinho nos países do velho mundo, ou estabilizou, ou diminuiu. Isto significa que estes países, que são tradicionalmente grandes consumidores de vinho, tentam agora expandir o seu negócio para países que tradicionalmente não o eram, nomeadamente Estados Unidos da América, Reino Unido, Rússia e Escandinávia. Existe

também a tendência global para produtos de melhor qualidade tanto na produção, como nos padrões de consumo.

Anderson et al. (2016) mostra que desde 1960 até 2016 o consumo de vinho no mercado global diminuiu (de quase 35% do consumo global de álcool para quase 15%), no entanto, o consumo de vinho no mercado asiático tem vindo a aumentar desde o ano de 1995 (400 megalitros para quase 2400 megalitros) .

Este autor, mostra também que para França, Itália, Espanha e Portugal, o consumo *per capita* de vinho em litros por ano tem vindo a diminuir, por outro lado, o consumo de vinho no novo mundo tem estado em crescimento desde 1960.

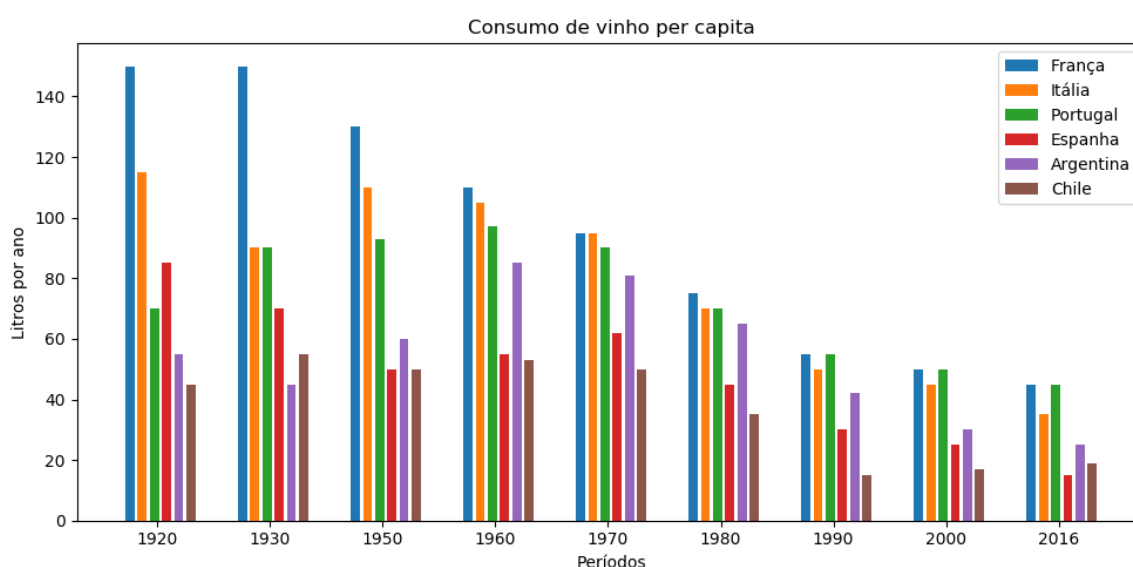


Figura 7: Consumo de vinho *per capita* do mercado tradicional europeu. Fonte: Anderson et al. (2016)

Segundo International Organization of Vine and Wine (2017), do mercado mundial, o país com mais consumo de vinho é os Estados Unidos da América, com 31.8 milhões de hectolitros de vinho. Em segundo lugar está a França, com 27 milhões de hectolitros, em terceiro a Itália com 22.5 milhões de hectolitros, em quarto lugar a Alemanha com 19.5 e em quinto a China com 17.3. Espanha tem um consumo anual de 9.9 milhões de hectolitros e Portugal um consumo de 4.6. De 2012 para 2016, o consumo global de vinho diminuiu 3 milhões de hectolitros (1.1%).

International Organization of Vine and Wine (2018) (figura 4) mostra que o consumo mundial de vinho tem aumentado, no entanto, Anderson et al. (2016) (figura 10) mostra que houve uma diminuição da cota de mercado do vinho para outros tipos de álcool.




Figura 8: Consumo de vinho *per capita* do mercado do novo mundo. Fonte: Anderson et al. (2016)

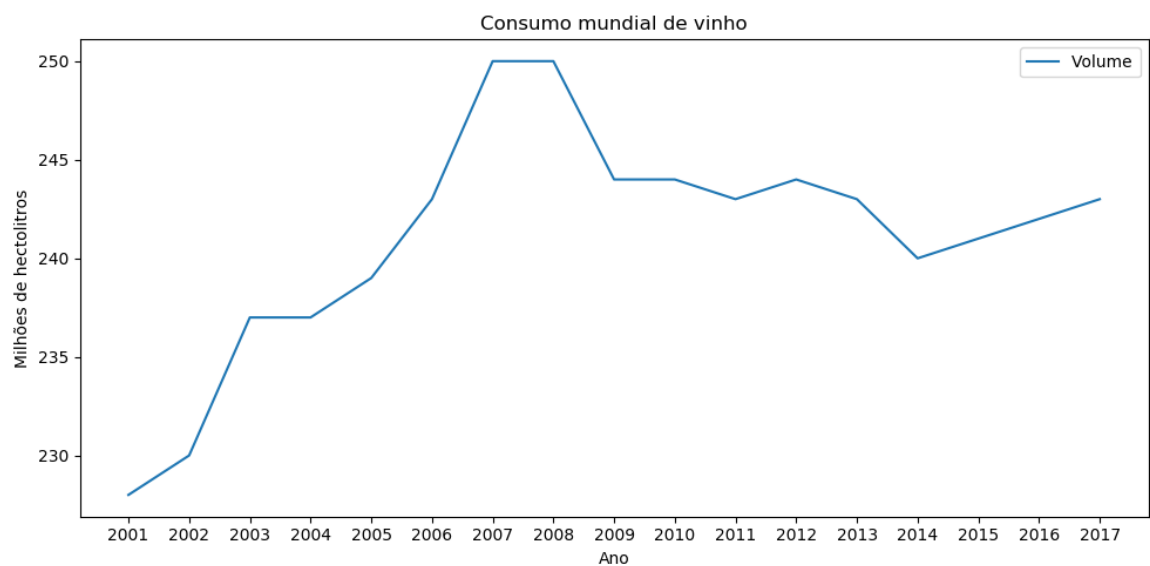


Figura 9: Consumo mundial de vinho. Fonte: Anderson et al. (2016)




Figura 10: Cota de mercado do vinho no mercado mundial. Fonte: Anderson et al. (2016)




Figura 11: Cota de mercado do Reino Unido nas exportações dos principais parceiros. Fonte: Anderson et al. (2017)

Capítulo III

Metodologia

3.1 Problema do estudo

A gestão do Working Capital é importante para uma empresa que tem que lidar com uma produção sazonal e que tem que gerir os seus prazos de pagamentos e de recebimento. Deloof (2003) mostra que existe uma relação entre a rentabilidade e a gestão do WCM para as empresas belgas. Raheman e Nasr (2007) obteve também resultados que mostra uma relação para as empresas paquistanesas. Segundo Lazaridis (2006) para se obter melhores resultados, as empresas devem otimizar os diferentes prazos - Prazo Médio de Recebimento, Prazo Médio de Pagamento e Prazo Médio de Rotação de Inventário.

As empresas da indústria vitivinícola são empresas que, derivado ao tipo de matéria-prima com que estão a lidar, têm que ter uma gestão apertada dos stocks e têm que estar preparadas para ruturas. International Organization of Vine and Wine (2018) indica que o ano de 2017 teve um dos piores volumes de produção da última década e isso é um fator importante a ter em conta neste tipo de empresas.

3.2 Pergunta de partida

Este estudo centra-se no WCM e nas suas variáveis e de que forma se pode otimizar estas variáveis de forma a aumentar a rentabilidade. No entanto é necessário saber o seguinte: **existe uma relação entre o WCM e o rendimento das empresas?** A resposta é-nos dada através de correlações entre as diferentes variáveis do estudo dos dados obtidos das empresas vitivinícolas de Espanha, França, Itália e Portugal.

3.3 Objetivos do estudo

Para empresas que têm um valor de mercado já definido e que cuja produção poderá não ter forma de aumentar para se poder aumentar o volume de vendas, torna-se complicado aumentar a rentabilidade. Por outro lado, os recentes estudos indicam que a produção tem uma tendência decrescente derivado às condições climáticas adversas. Para tal, este estudo tem os seguintes objetivos:

- Encontrar uma relação entre a rentabilidade e o Working Capital;
- Calcular a significância desta relação na rentabilidade;
- Calcular a rentabilidade esperada perante um determinado valor nas diferentes variáveis do WCM através de um sistema de redes neuronais.

3.4 Hipóteses do estudo

Para atingir os objetivos descritos, as hipóteses propostas para este estudo testam as diferentes relações para as empresas de cada país e de uma forma global. As hipóteses são as seguintes:

h1 Existe uma correlação entre o Ciclo de Conversão de Caixa e a rentabilidade das empresas:

- a** para as empresas de Espanha;
- b** para as empresas de França;
- c** para as empresas de Itália;
- d** para as empresas de Portugal;
- e** para todas as empresas.

h2 Existe uma correlação entre o Prazo Médio de Pagamento e a rentabilidade das empresas:

- a** para as empresas de Espanha;
- b** para as empresas de França;
- c** para as empresas de Itália;
- d** para as empresas de Portugal;

e para todas as empresas.

h3 Existe uma correlação entre o Prazo Médio de Recebimento e a rentabilidade das empresas:

a para as empresas de Espanha;

b para as empresas de França;

c para as empresas de Itália;

d para as empresas de Portugal;

e para todas as empresas.

h4 Existe uma correlação entre o Prazo Médio de Rotação de Inventário e a rentabilidade das empresas:

a para as empresas de Espanha;

b para as empresas de França;

c para as empresas de Itália;

d para as empresas de Portugal;

e para todas as empresas.

h5 Existe uma correlação entre o Ciclo Operacional e a rentabilidade das empresas:

a para as empresas de Espanha;

b para as empresas de França;

c para as empresas de Itália;

d para as empresas de Portugal;

e para todas as empresas.

h6 Um sistema de redes neuronais artificiais consegue encontrar uma relação entre o Ciclo de Conversão de Caixa e a rentabilidade das empresas;

h7 É possível prever qual o EBITDA de uma empresa através de uma mudança nas variáveis do Ciclo de Conversão de Caixa.

3.5 Construção das variáveis

Para este estudo é necessário calcular o Working Capital (neste caso o Ciclo de Conversão de Caixa) e por isso, é necessário utilizar as variáveis Prazo Médio de Recebimento,

Prazo Médio de Rotação de Inventário e Prazo Médio de Pagamento. As seguintes fórmulas demonstram como calcular as variáveis do CCC e foram introduzidas por Keown et al. (2003) em “Foundations of Finance”:

$$CCC = CO - DPO \quad (3.1)$$

Onde:

CCC = Ciclo de Conversão de Caixa

OC = OC

DPO = Prazo Médio de Pagamento

$$OC = DSO + DIO \quad (3.2)$$

Onde:

OC = Ciclo Operacional

DSO = Prazo Médio de Recebimento

DIO = Prazo Médio de Rotação de Inventário

$$DPO = \frac{AP}{P} \times 365 \quad (3.3)$$

Onde:

DPO = Prazo Médio de Pagamento

AP = Contas de Fornecedores

P = Compras

$$DIO = \frac{I}{P} \times 365 \quad (3.4)$$

Onde:

DIO = Prazo Médio de Rotação de Inventário

I = Inventários

P = Compras

$$DSO = \frac{AR}{S} \times 365 \quad (3.5)$$

Onde:

DSO = Prazo Médio de Recebimento

AR = Contas de Clientes

S = Vendas

3.6 Fonte dos Dados

Os dados para este estudo foram obtidos através da base de dados europeia “Amadeus” e foram selecionadas todas as empresas produtoras de vinho, com dados disponíveis, de Portugal, Espanha, França e Itália. Estes dados são compostos por 4109 empresas dos quatro países e retratam 29.376 anos empresariais. Algumas destas empresas têm dados referentes aos últimos 10 anos de atividade e outras apenas ao último ano, no entanto, para a análise através de redes neuronais, este facto não é relevante. Após a filtragem de dados para remover os “outliers”, ficaram apenas 324 empresas e 521 anos empresariais. Na tabela 12 verifica-se que a maior parte das empresas utilizadas neste estudo são espanholas (149 empresas) e apenas 38 empresas são portuguesas.

Último ano registado das empresas					
Ano	País				Total
	ES	FR	IT	PT	
2005	0	1	0	0	1
2006	0	1	0	1	2
2007	0	4	2	2	8
2008	7	2	3	2	14
2009	6	2	1	1	10
2010	14	14	2	6	36
2011	13	9	7	2	31
2012	14	6	6	4	30
2013	16	13	2	2	33
2014	22	7	7	7	43
2015	18	11	9	2	40
2016	37	12	4	9	62
2017	2	9	3	0	14
Total	149	91	46	38	324

Tabela 12: Empresas produtoras de vinho

Anos empresariais por país					
Ano	País				Total
	ES	FR	IT	PT	
2005	0	1	0		1
2006	0	1	0	1	2
2007	0	6	4	3	13
2008	16	10	6	4	36
2009	18	5	7	4	34
2010	24	23	8	8	63
2011	27	12	11	4	54
2012	24	11	10	6	51
2013	27	16	9	5	57
2014	36	10	11	10	67
2015	33	15	12	2	62
2016	37	14	7	9	67
2017	2	9	3		14
Total	244	133	88	56	521

Tabela 13: Anos empresariais por país

3.7 Correlação de Pearson

As quatro primeiras hipóteses deste estudo estão relacionadas com a correlação das variáveis do Working Capital, que neste caso é retratado pelo Ciclo de Conversão de Caixa, e o Resultado Operacional Bruto. A correlação de Pearson (eq. 3.6) é uma fórmula que compara duas variáveis e representa a sua relação. Uma relação com valor $r = 1$, mostra que as duas variáveis estão interligadas e que quando uma das variáveis aumenta, a outra variável aumenta na mesma proporção. Quando $0 < r < 1$, a relação é positiva mas as variáveis não variam na mesma proporção. Quando $-1 < r < 0$ a relação é negativa e as variáveis variam de forma inversa, mas não na mesma proporção. Por fim, quando $r = -1$, as variáveis têm uma variação inversamente proporcional. No entanto, é necessário saber se esse valor da correlação tem um impacto significativo. Para isso calcula-se a significância da correlação - equação 3.7. A significância retorna a probabilidade dos dados não estarem relacionados mas existir uma correlação. Ou seja, quanto menor for a significância, maior é a certeza que existe uma correlação entre as variáveis. Por norma, a significância desejada deve ser $s \leq 0.05$.

$$r = \frac{n(\sum(xy)) - (\sum x)(\sum y)}{\sqrt{[n(\sum x^2) - (\sum x)^2][n(\sum y^2) - (\sum y)^2]}} \quad (3.6)$$

Onde:

r = Correlação de Pearson

x = Primeira variável

y = Segunda variável

$$p = \frac{r}{\sqrt{(1 - r^2)/(N - 2)}} \quad (3.7)$$

Onde:

p = Teste da Significância da Correlação de Pearson

r = Correlação de Pearson

N = Tamanho da Amostra

3.8 Redes Neurais Artificiais

Nos últimos anos têm-se vindo a acentuar a importância da análise de dados para se retirar mais informações sobre os utilizadores de determinados bens ou serviços e o método atualmente mais utilizado é a Inteligência Artificial (AI).

Segundo Goodfellow et al. (2016), no início da AI, os problemas a serem resolvidos eram difíceis de resolver para o Ser Humano, mas relativamente simples para o computador. Estes problemas eram normalmente descritos como uma lista de regras matemáticas. No entanto, o verdadeiro desafio aparece quando o objetivo é resolver problemas que são simples para o Ser Humano, mas que não obedecem a regras formais, tais como problemas que são resolvidos com recurso à intuição e automáticos, por exemplo, reconhecer palavras ou caras numa imagem.

A dificuldade existe porque a maioria dos problemas têm múltiplos fatores e todos eles podem afetar os resultados obtidos. No caso de um programa que deteta fraudes bancárias, qualquer um dos dados obtidos das contas dos clientes pode ser o fator decisivo para a classificação de “fraude” ou “não fraude”, mas não existe uma regra formal que nos ajude a classificar. Para este autor, é irónico o facto de tarefas abstratas e formais serem as mais difíceis para o Ser Humano, mas as mais fáceis para um computador e mostra que existem diferentes tipos de sistemas de resolução de problemas dentro da Inteligência Artificial (figura 12).

Para Cortez e Neves (2000), as redes neuronais supervisionadas aprendem através de dados que incluem as variáveis em análise e as respostas corretas para as mesmas. Neste caso, a rede aprende a partir de um conjunto de padrões e compara os resultados obtidos do processo de aprendizagem aos resultados registados nos dados. Após uma iteração do algoritmo de aprendizagem (Epoch) os pesos são ajustados para o resultado da rede se aproximar ao resultado real. A aprendizagem é então conseguida após um número determinado de Epoch e em que o erro (normalmente avaliado através do cálculo do *Erro Quadrático Médio*) se situa numa margem aceitável.

Schmidhuber (2014) refere que uma rede neuronal *standard* consiste em muitos processadores simples, chamados neurónios, conectados entre si e cada um deles produz uma sequência de valores reais ativados. Os neurónios responsáveis pelos valores de entrada (input) são ativados através de sensores que percecionam o ambiente e outros neurónios são ativados através do peso dos neurónios anteriores. Alguns destes neurónios podem influenciar o ambiente ao acionarem diferentes ações. A aprendizagem é o facto de encontrar um

valor para o peso atribuído a determinado input que faz a rede neuronal chegar ao resultado esperado.

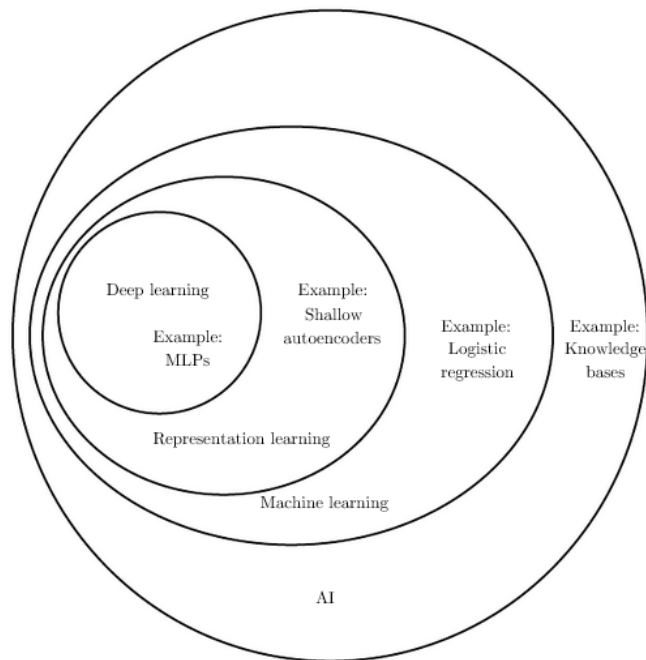


Figura 12: Diagrama de Venn sobre os sistemas de Inteligência Artificial - Goodfellow et al. (2016)

Segundo Cortez e Neves (2000), estas redes assemelham-se ao comportamento do cérebro humano em dois aspetos:

- O conhecimento é adquirido a partir de um ambiente, através de um processo de aprendizagem;
- O conhecimento é armazenado nas conexões (sinapses) entre os diferentes *layers*.

Estes autores referem que os *layers* ou *nodos* são um conjunto de conexões entre diferentes neurónios e cada uma dessas conexões está representada por um peso w_{ij} , em que i representa o objeto de estudo e j representa de onde partiu o sinal. Daí, o input x_j é multiplicado pelo respetivo peso w_{ij} , podendo também existir uma conexão extra, *bias*, que estabelece uma tendência ou inclinação no processo para que sejam corrigidas as condições operacionais do respetivo *layer*.

A estrutura geral de *layer* (figura 14) é normalmente composta por um integrador (g) e uma função de ativação (f). O integrador tem como função reduzir os input em um único valor. Neste passo é utilizado normalmente a adição.

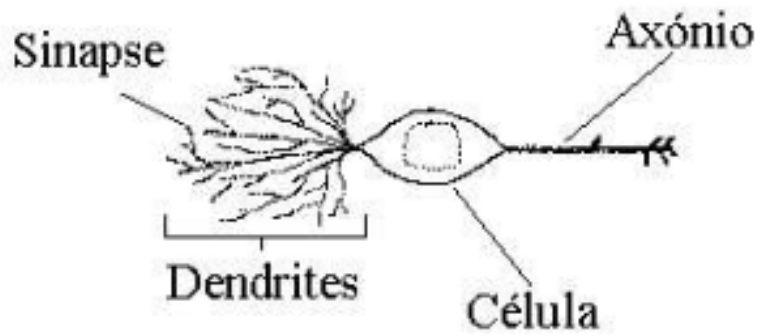


Figura 13: Estrutura de um neurónio natural - Cortez e Neves (2000)




Figura 14: Estrutura geral de um nodo - Cortez e Neves (2000)

$$u_i = g(1 * w_{i0}, x_1 * w_{i1}, x_2 * w_{i2}, \dots, x_n * w_{in}) \quad (3.8)$$

Onde:

- u_i = ganho do nodo i
- g = integrador
- x_n = input
- w_{in} = peso do neurónio n

$$s_i = f(u_i) \quad (3.9)$$

Onde:

s_i = output do nodo s_i

$f(u_n)$ = estrutura do nodo

Segundo Schmidhuber (2014), dependendo do problema, para se chegar ao resultado desejado pode ser necessário uma cadeia de reações em diferentes passos (*layers*), em que cada um destes passos, os neurónios transformam a ativação da rede. *Deep Learning* é o facto de atribuir o peso mais preciso possível ao longo dos passos da rede neuronal, principalmente através da aplicação de Retropropagação (Back Propagation), como por exemplo, *Gradient Descent*.

Cortez e Neves (2000) explicam que o algoritmo de Back Propagation é o algoritmo mais popular e que este prevalece como um marco para a AI, pois constitui um método eficiente para o treino das redes neuronais artificiais. Esta função procura um mínimo da função de erro nos pesos atribuídos aos neurónios através de métodos de gradiente descendente. Estes autores afirmam que a combinação de pesos que minimiza a função de erro é considerada a solução final para o problema de aprendizagem. O algoritmo de Back Propagation é feito em dois passos:

1. Em frente, os input são fornecidos no primeiro *layer*, propagando-se em frente, através de todos os *layers* (através das funções 3.8 e 3.9) em que o integrador (g) utiliza a função de adição:

$$u_i = \sum_j s_j w_{ij} \quad (3.10)$$

O erro é calculado através de uma função de custo (Loss Function) , normalmente o *Erro Quadrático Médio*, dado por:

$$MSE = \frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2 \quad (3.11)$$

2. Back Propagation, o erro é propagado para trás, até ao input *layer*. Os pesos são ajustados mediante a regra de *Widrow-Hoff* (equação 3.12) e começa uma nova iteração.

$$\Delta w = \eta \nabla \xi \quad (3.12)$$

Onde:

η = taxa de aprendizagem

$\nabla\xi$ = gradiente da Loss Function

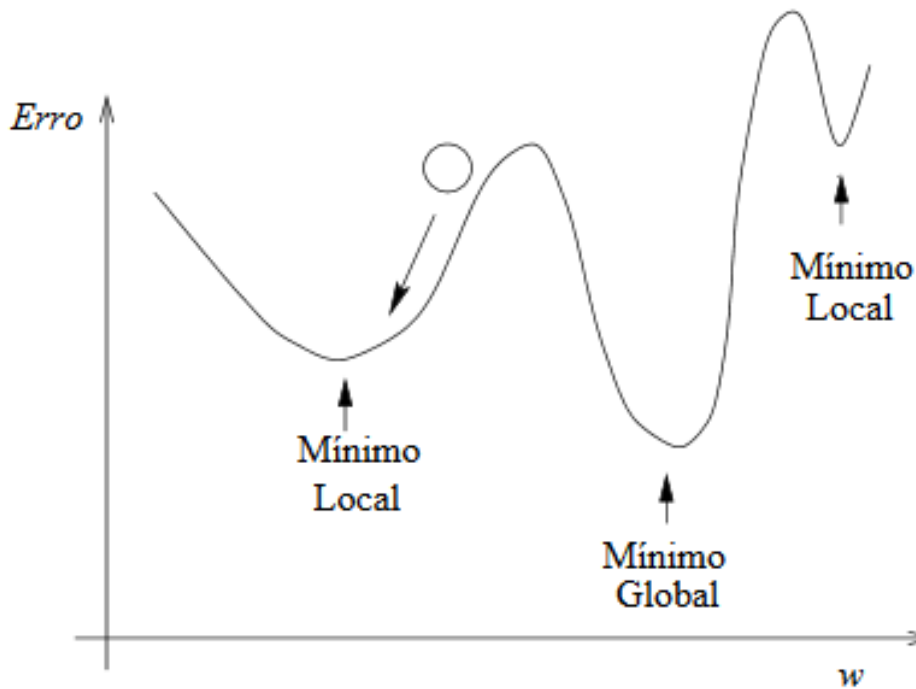


Figura 15: Mínimos locais e globais (*Gradient Descent*) - Cortez e Neves (2000)

A função ReLU é a função de ativação recomendada para a maioria das *feedforward neural networks*. Ao aplicar esta função ao output de uma transformação linear (*layer*), resulta numa transformação não linear. Pelo facto desta função ser linear, as propriedades dos dados são mantidos e isso resulta numa maior facilidade de optimização com o *Gradient Descent*.

$$\phi(x) = \max(0, x) \quad (3.13)$$

Onde:

$\phi(x)$ = ReLU

max = valor mais alto de x

x = input

Segundo Goodfellow et al. (2016), as *Deep Feedforward Networks* ou *Multilayer Perceptrons*, são o modelo mais utilizado de redes neuronais de *Deep Learning*. Estes modelos são chamados de *feedforward* porque a informação (input) flui através da função enquanto é avaliada (ativação) até chegar ao output. Neste modelo de redes neuronais não existe um *feedback*, ou seja, o output anterior não afeta os *inputs* que serão agora avaliados. O nome *Deep* nas redes neuronais veio do facto dos diferentes *layers* estarem conectados entre si e conforme o número de *layers*, maior será a profundidade da rede.

$$f(x) = f^3(f^2(f^1(x))) \quad (3.14)$$

Onde:

$f(x)$ = Deep Neural Network

$f^1(x)$ = Layer 1

$f^2(x)$ = Layer 2

$f^3(x)$ = Layer 3

x = input

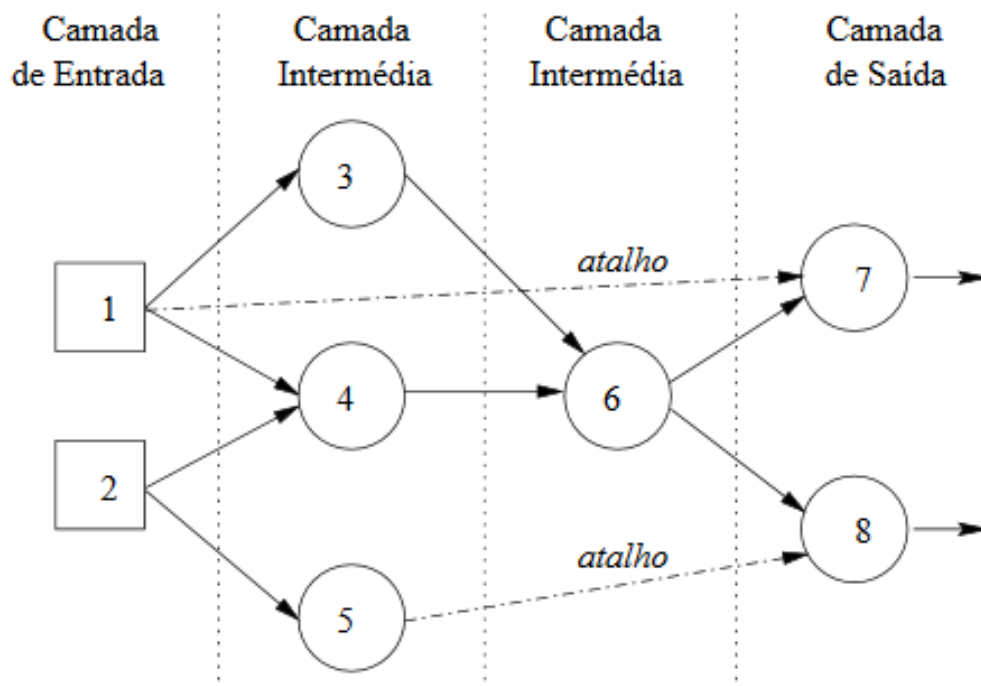


Figura 16: Estrutura de uma rede neuronal multi camada (*Multi Layer Perceptron*) - Cortez e Neves (2000)

Uma aplicação prática deste tipo de rede neuronal é a aprendizagem da função “Ou” Exclusivo (XOR). Esta função, é uma operação lógica que só tem um valor verdadeiro se e apenas se um dos input tiver um valor verdadeiro.

Tabela de “A XOR B”		
Input		Output
x_1	x_2	
0	0	0
0	1	1
1	0	1
1	1	0

Tabela 14: Tabela lógica “A XOR B”. (0 : *Falso* e 1 : *Verdadeiro*)

A dificuldade na resolução deste tipo de problema centra-se no facto de o resultado não ter um valor linear, ou seja, para $x_1 = 0$, o resultado tem de aumentar conforme x_2 aumenta. No entanto, para $x_1 = 1$, o resultado tem de diminuir conforme x_2 aumenta. Um modelo linear tem de aplicar um coeficiente w_2 em x_2 . A dificuldade aparece quando não se pode utilizar o valor de x_1 para alterar o coeficiente de x_2 .

Após ter as tabelas dos pesos dos respetivos layers e neurónios, as fórmulas para se prever o resultado dado um determinado input são as seguintes:

$$x = \sum_{n=1}^n [i_n w_n + b] \quad (3.15)$$

Onde:

x = Resultado do neurónio

i = Valor do input i

w = Peso do input i

b = *Bias* do neurónio x

n = Número de inputs

$$y = \sum_{n=1}^n [x_i w_i + b] \quad (3.16)$$

Onde:

y = Resultado do neurónio
 x = Valor do neurónio x
 w = Peso do neurónio x
 b = *Bias* do neurónio y
 n = Número de neurónios da camada anterior

$$p = \sum_{n=1}^n [y_i w_i + b] \quad (3.17)$$

Onde:

p = Output
 y = Valor do neurónio y
 w = Peso do neurónio y
 b = *Bias* do neurónio p
 n = Número de neurónios da camada anterior

3.9 Estudo de caso das empresas vitivinícolas

Neste estudo será utilizada uma rede neuronal multi camada (*Multi Layer Perceptron*) para analisar a relação entre as diversas variáveis do WCM e a rentabilidade das empresas.

Como primeiro passo para a análise dos dados, os dados serão divididos em três partes: training-set, validation-set e test-set e normalizados para as diferentes variáveis (*features*) terem o mesmo impacto na rede neuronal. A primeira parte refere-se ao número de dados que serão utilizados para o algoritmo de aprendizagem observar padrões e estabelecer os pesos dos input. Após a aprendizagem da rede neuronal, é necessário que seja avaliada a sua eficácia (utilizando os dados do validation-set) e, caso necessário, que esta seja alterada/adaptada para aumentar a sua precisão na previsão dos dados (hiper-parametrização). Por fim, a rede é testada, e o resultado da sua eficácia é obtido. Não existe nenhuma regra para dividir estes dados, mas é normal utilizar uma divisão 80-10-10, ou seja, 80% training-set, 10% validation-set e 10% test-set. A seleção dos dados para cada uma das partes é feita através de Amostra Simples Aleatória (Simple Random Sample), Lohr (1999), que consiste em seleccionar os dados aleatoriamente. Segundo Reitermanová (2010) este sistema é o mais co-

num, é eficiente e fácil de implementar. Após a divisão dos dados, estes serão normalizados através da fórmula *MinMax Scaler* (equação 3.18) .

$$x' = \frac{x - \min(x)}{\max(x) - \min(x)} \quad (3.18)$$

Onde:

x' = valor normalizado

x = valor inicial

$\min(x)$ = valor mais baixo dos dados

$\max(x)$ = valor mais alto dos dados

A rede neuronal é então composta com um input *layer*, um número de *hidden layers* que têm como objetivo fazer mais computações e atribuir novos pesos para atingir um resultado e um output *layer*. O input *layer* começa com um número de neurónios igual ao número de variáveis e com uma função de ativação ReLU. Segundo Bengio (2013) o número de *hidden layers* deve ser determinado através do método tentativa-erro, em que consiste em aumentar progressivamente o número de *layers* até que a rede não obtenha um melhor resultado que o número anterior. Quando a rede obtiver o melhor resultado, acrescenta-se um Dropout Layer. Este *layer* consiste em eliminar aleatoriamente alguns neurónios para a rede adaptar os pesos e diminuir a margem de erro. O output *layer* dá-nos o resultado final que será utilizado para avaliar se a rede neuronal consegue chegar ao valor esperado e com que precisão consegue prever esse valor.




Figura 17: Comparação da margem de erro entre a utilização de um Dropout Layer e sua não utilização - Reitermanová (2010)

Capítulo IV

Resultados

4.1 Outliers

Na análise dos dados obtidos das empresas vitivinícolas é necessário ter em conta a presença de *outliers* - Observação que se encontra destacada das restantes observações num conjunto de dados. Estas empresas encontram-se tão destacadas do resto, que causam anomalias no cálculo das médias dos diversos indicadores. Pelo facto das médias serem influenciadas pela presença de dados dispersos, é necessária a utilização de métricas estatísticas que não são influenciáveis pelos *outliers*. Um exemplo deste tipo de métricas é a análise por quartis. A análise por quartis utiliza a mediana ao invés da média, o que significa que centra-se na sequência de valores e não nos valores mais altos ou mais baixos. Esta análise torna-se relevante para este estudo, pois pode mostrar que a diferença entre as empresas dos países estudados se situa na forma como estas gerem estas variáveis. Estas variáveis serão depois utilizadas para calcular a sua correlação com a rentabilidade das empresas. Os dados que encontravam a baixo do primeiro quartil e os dados que ultrapassavam o terceiro quartil foram considerados *outliers* e foram retirados.

4.2 Dados

Na tabela 15, observa-se que em média, as empresas italianas são as que dão mais crédito aos clientes, isto vê-se através do valor da conta de clientes, que é superior aos das empresas dos outros países. Na média da margem de lucro, as empresas portuguesas são as que têm uma maior margem enquanto as empresas francesas são as que têm um lucro mais baixo. Destes países, as empresas francesas têm o valor da conta de clientes 3.5 vezes superior ao da conta de fornecedores, enquanto as empresas italianas e italianas têm uma diferença de

1.05 vezes. Isto pode significar que as empresas que distribuem o encargo do crédito dos clientes pelos seus fornecedores têm mais rentabilidade. Isto pode estar relacionado com o facto do Prazo Médio de Pagamento igual ou superior ao Prazo Médio de Recebimento. Segundo a tabela 15 verifica-se que as empresas que têm maior rentabilidade também têm um maior valor de dívida de longo prazo comparado ao valor de compras, isto é verificável para as empresas portuguesas que têm um valor de dívida de longo prazo superior ao valor das compras. Pode ser o caso destas empresas adiarem os juros de empréstimos e amortizações de capital para um prazo mais alargado e assim manter também um valor mais elevado de *cash flow* e crédito aos clientes. Através destes dados verifica-se que o valor médio de vendas das empresas italianas é quase o dobro das empresas dos outros países combinadas.

Nas figuras 18, 19 e 20 estão representadas as variações das médias anuais das variáveis por país. É possível verificar que em quase todas as variáveis as empresas portuguesas se destacam das empresas dos restantes países, com exceção do EBITDA, em que as empresas italianas apresentam o maior valor. No caso do EBITDA, as empresas espanholas têm a média mais baixa dos países estudados.

Comparação das médias dos países				
Variáveis	ES	FR	IT	PT
C. Clientes	438 417,37€	1 071 494,45€	3 479 762,38€	904 397,20€
C. Fornecedores	278 137,22€	306 932,48€	3 297 775,73€	559 398,55€
Vendas	1 589 487,34€	4 544 775,53€	11 639 683,88€	1 853 048,91€
Compras	946 853€	3 307 719,35€	8 248 949,55€	1 031 394,82€
EBITDA	145 861,03€	240 602,29€	626 172,65€	247 532,66€
R. Operacional	1 610 502,2€	4 736 827,05€	1 1903 471,24€	1 968 279,57€
Margem de Lucro	2,64	1,04	2,61	3,18
Cash Flow	108 801,34€	219 073,89€	410 911,27€	164 165,16€
Dívida L/P	652 219,88€	1 251 633,74€	1 293 722,77€	1 549 232,84€
DPO	106	36	150	202
DIO	253	140	150	320
DSO	102	86	109	168
OC	355	225	259	488
CCC	250	190	109	285

Tabela 15: Comparação das médias dos países




Figura 18: Representação gráfica da variação das variáveis ao longo dos anos - CCC e DPO

Nesta figura observa-se que as empresas portuguesas são as que apresentam um maior número de dias de Ciclo de Conversão de Caixa, seguindo-se pelas empresas espanholas, as empresas francesas e por fim as empresas italianas. Por outro lado, no gráfico do Prazo Médio de Pagamento observa-se que a ordem é diferente, em que as empresas portuguesas são as que apresentam uma maior número de dias de Prazo Médio de Pagamento, seguindo-se pelas empresas italianas, as empresas espanholas e pelas empresas francesas. O facto das empresas italianas apresentarem um valor inferior de CCC, dado o elevado número de dias de DPO, pode ser explicado através de uma boa gestão do Prazo Médio de Recebimento e Prazo Médio de Rotação de Inventário.




Figura 19: Representação gráfica da variação das variáveis ao longo dos anos - DIO e DSO

Nesta figura as empresas portuguesas também apresentam o maior número de dias nas variáveis Prazo Médio de Rotação de Inventário e Prazo Médio de Recebimento. As empresas italianas e as empresas francesas apresentam uma gestão destas variáveis muito parecidas. As empresas espanholas apresentam um valor de DSO semelhante ao das empresas francesas e italianas. Das variáveis do Working Capital, as empresas portuguesas são as que apresentam um maior valor.




Figura 20: Representação gráfica da variação das variáveis ao longo dos anos - OC e EBITDA

As empresas italianas são as que apresentam um maior Resultado Operacional Bruto das empresas analisadas e as com menor são as empresas espanholas. As empresas com maior número de dias de Ciclo Operacional são as empresas portuguesas e as com menor são as francesas, este resultado é calculado através do Prazo Médio de Recebimento e do Prazo Médio de Rotação de Inventário. Através destes gráficos não é possível concluir se existe uma relação entre o WCM e o EBITDA, pois a empresa com menor CCC é a que tem mais rendimento, mas o oposto não é observado.

4.3 Estatística Descritiva

As figuras referentes aos quartis retratam os dados das tabelas 27, 28, 29, e 30 do apêndice e comparam os 4 países na dispersão dos dados pelas diferentes variáveis. Nestas figuras, os círculos pretos representam os outliers, a linha laranja representa a mediana ou o segundo quartil, o retângulo inferior representa 25% das empresas com o valor mais baixo e o retângulo superior representa 25% das empresas com o valor mais alto. A linha vertical, que se situa em baixo do retângulo inferior representa a distância até o valor mínimo e a linha vertical a cima do retângulo superior representa a distância até o valor máximo.

Na figura 21 está representada a dispersão do CCC das empresas e observa-se 25% das empresas espanholas têm um CCC entre os 204 dias e os 248 dias e outros 25% têm entre 248 e 292 dias. Por outro lado, 25% das empresas francesas apresenta um CCC entre 175 e os 195 dias e os outros 25%, entre 195 e 211 dias. Isto mostra que as empresas espanholas têm um Ciclo de Conversão de Caixa mais disperso entre si. O facto das empresas se encontrarem mais dispersas mostra que o tipo de gestão das mesmas não é similar, ou seja, não existe uma tendência global para a gestão do CCC. As empresas italianas são semelhantes às empresas espanholas em termos de dispersão da gestão do CCC. Das empresas italianas, 25% gere o Ciclo de Conversão de Caixa entre os 74 e os 111 dias e outros 25%, entre os 111 e os 139 dias. As empresas portuguesas apresentam a maior dispersão do CCC das empresas dos quatro países, sendo que 25% das empresas apresentam um CCC entre os 223 e os 295 e outros 25% entre os 295 e os 343 dias.

Em relação à dispersão do Ciclo Operacional (figura 22), a situação é semelhante, em que se verifica uma maior dispersão entre as empresas portuguesas, e uma menor dispersão entre as empresas francesas e as empresas italianas. As empresas francesas são as que apresentam um menor OC, em que 25% se situa entre os 208 e 222 dias e outros 25% entre 222 e 243 dias. As empresas italianas encontram-se com um OC ligeiramente superior, no primeiro quartil este está compreendido entre os 243 e os 260 dias e no terceiro, entre os 260 e os 276 dias. Por outro lado, as empresas espanholas já apresentam uma maior dispersão entre si e isso verifica-se no aumento da amplitude desta variável. No primeiro quartil, estas empresas encontram-se entre os 315 e os 355 dias e no terceiro quartil, entre os 355 e os 393 dias. As empresas portuguesas são as que têm um maior valor do Ciclo Operacional. No primeiro quartil estão entre os 450 e os 490 dias e as do terceiro estão entre os 490 e os 528 dias de OC.

A situação altera-se ligeiramente na dispersão do Prazo Médio de Recebimento representada na figura 23. Nesta figura verifica-se que as empresas italianas estão mais dispersas

nesta variável do que nas variáveis anteriores. As empresas francesas continuam a ser as com menos dispersão e neste caso, 25% das empresas têm um DSO compreendido entre os 73 e os 84 dias e outros 25% entre os 84 e os 99 dias. As empresas espanholas mantêm esta variável entre os 82 e os 102 dias e os 102 e os 121 dias para o primeiro e terceiro quartis respetivamente. Para as empresas italianas o DSO encontra-se entre os 93 e os 111 dias e os 111 e os 122 dias. Nesta figura, as empresas mais dispares são as portuguesas, que gerem o seu Prazo Médio de Recebimento entre os 140 e os 161 dias e os 161 e os 198 dias para o primeiro e terceiro quartis.




Figura 21: Representação gráfica dos quartis do Ciclo de Conversão de Caixa das empresas

Na figura 24 verifica-se uma alteração, em que as empresas espanholas e italianas têm uma dispersão semelhante e que as empresas italianas aproximam-se dos valores das empresas portuguesas. As empresas portuguesas são as mais dispersas na gestão do Prazo Médio

de Pagamento. Neste caso, as empresas francesas apresentam no primeiro quartil um valor entre os 18 e os 26 dias, as empresas espanholas entre os 72 e os 102 dias e as empresas italianas entre os 123 e os 150 dias. Por outro lado, as empresas portuguesas apresentam no primeiro quartil um DPO entre os 147 e os 201 dias. No segundo quartil das empresas francesas, espanholas, italianas e portuguesas, os valores encontra-se entre os 26 e os 41 dias, os 102 e os 143 dias, os 150 e os 181 dias e entre os 201 e os 247 dias respectivamente.




Figura 22: Representação gráfica dos quartis do Ciclo Operacional das empresas

A dispersão do DIO (figura 25) das empresas francesas e das empresas italianas é semelhante no primeiro e terceiro quartis. No primeiro quartil, as empresas têm um Prazo Médio de Rotação de Inventário entre os 121 e os 138 dias e entre os 128 e os 151 dias respectivamente para os dois países. No terceiro quartil, o DIO encontra-se entre os 138 e os 159 dias e os 151 e os 166 dias respectivamente. As empresas espanholas têm uma maior disparidade

e apresentam nos seus quartis os valores entre os 213 e os 252 dias e entre os 252 e os 287 dias. A disparidade entre as empresas portuguesas é verificada mais uma vez e os valores do DIO encontra-se entre os 285 e os 326 dias e os 326 e os 369 dias para o primeiro e terceiro quartis respetivamente.




Figura 23: Representação gráfica dos quartis do Prazo Médio de Recebimento das empresas

Ao contrário das figuras referidas anteriormente, a figura 26 mostra que no caso do Resultado Operacional Bruto, as empresas italianas são as que têm uma maior dispersão dos dados analisados. As empresas espanholas mostram-se as com menos EBITDA de todas as empresas. Nesta figura, as empresas espanholas estão repartidas dentro de um EBITDA com valores entre os 27 mil e os 536 mil euros, enquanto que as empresas francesas têm um rendimento entre os 90 mil e os 619 mil euros. As empresas portuguesas têm uma maior dispersão do que as empresas francesas e espanholas e menor do que as empresas italianas,

em que o EBITDA encontra-se entre os 64 mil e os 816 mil euros. As empresas italianas são as que atingem um maior rendimento, o EBITDA situa-se entre os 226 mil e os 1.58 milhões de euros.




Figura 24: Representação gráfica dos quartis do Prazo Médio de Pagamento das empresas




Figura 25: Representação gráfica dos quartis do Prazo Médio de Rotação de Inventário das empresas

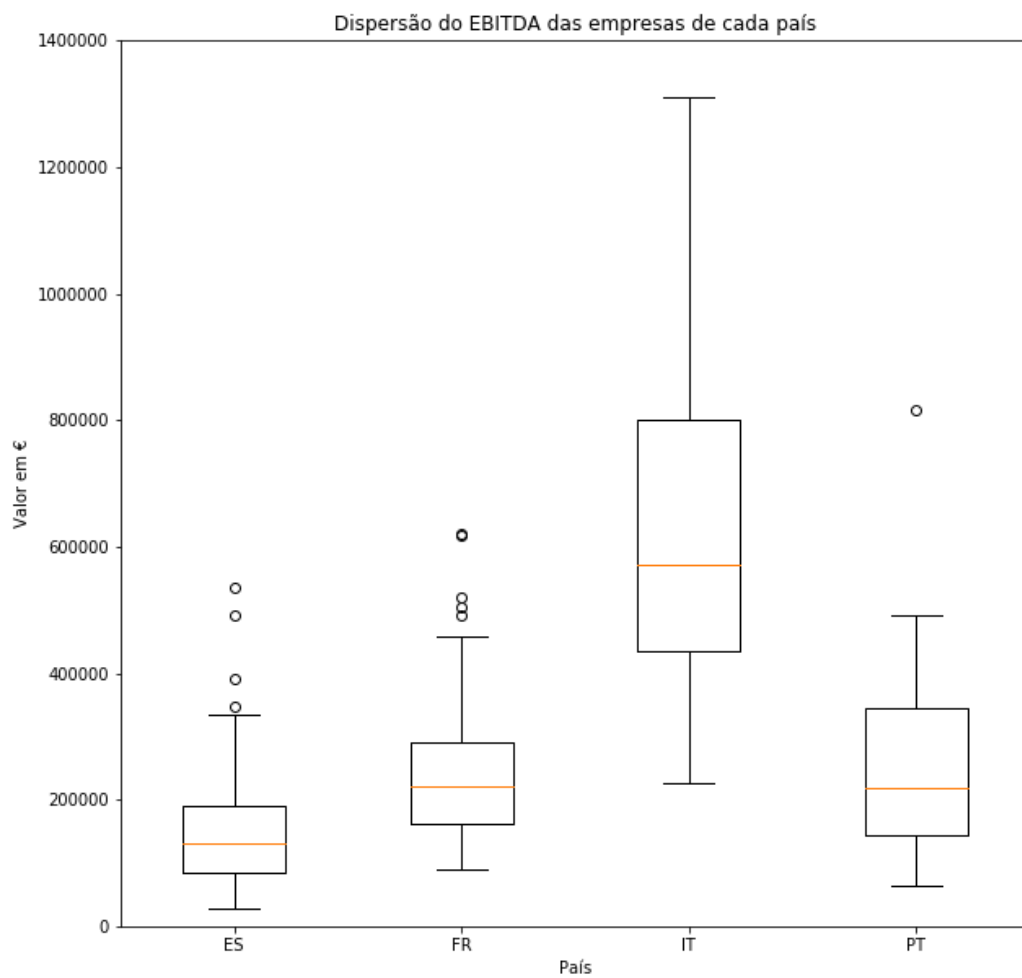


Figura 26: Representação gráfica dos quartis do Resultado Operacional Bruto das empresas

4.4 Correlação das variáveis

Nas tabelas 16 e 17 estão representadas as correlações das variáveis das empresas de Espanha, França, Itália e Portugal. Estas tabelas mostram o valor da correlação de Pearson (r) e a significância da correlação (p). A significância mede a probabilidade de uma correlação existir quando os dados não estão relacionados. Os melhores valores esperados para uma correlação de Pearson são $|r| \rightarrow 1$ e $p \rightarrow 0$, sendo que os dados têm uma correlação forte e uma probabilidade de esta existir e os dados não estarem relacionados é nula.

No resultado da correlação de Pearson das empresas espanholas, representados na tabela 16, observa-se que na generalidade as variáveis têm uma relação fraca com o EBITDA e a significância mostra que estes dados não são relevantes. Por outro lado, as empresas francesas já apresentam uma melhor relação das variáveis com o EBITDA e o OC é relevante para o rendimento das empresas. Este dado mostra-se significativo ($p \leq 0.05$) e está negativamente correlacionado com o EBITDA. O CCC está negativamente correlacionado com o rendimento, no entanto, a significância está acima do aceitável.

Resultados da correlação de Pearson				
Variáveis	Espanha		França	
	Pearson (r)	Significância (p)	Pearson (r)	Significância (p)
CCC	0.03	0.67	-0.14	0.1
DPO	0.05	0.4	0.03	0.73
DIO	0.09	0.17	-0.16	0.07
DSO	0	1	-0.03	0.77
OC	0.09	0.16	-0.19	0.03

Tabela 16: Resultados da correlação de Pearson entre as variáveis do Working Capital e a rentabilidade

Na tabela 17, as empresas italianas mostram uma correlação quase nula entre o CCC e a rentabilidade, mas a correlação do Prazo Médio de Recebimento com a rentabilidade é moderada e é significativa. As empresas portuguesas mostram uma correlação geral positiva entre as variáveis e a rentabilidade, sendo que a variável que mais se destaca é o CCC com uma correlação forte com o EBITDA com uma significância aceitável. Apesar da significância da correlação Prazo Médio de Pagamento ultrapassar o valor aceitável, encontra-se muito próxima de se tornar relevante. Destas variáveis, a Prazo Médio de Pagamento não tem uma correlação com a rentabilidade para as empresas italianas, mas existe uma alta probabilidade de este valor não representar a realidade. O Prazo Médio de Rotação de Inventário não tem uma relação com a rentabilidade para as empresas portuguesas e tal como o caso anterior, existe uma alta probabilidade de este valor não representar a realidade.

A tabela 18 mostra a correlação das variáveis independentemente no âmbito global e a

respetiva significância. A significância é perfeita para as correlações (igual a zero), exce-
tuando para Prazo Médio de Recebimento que é igual a 0.02. E tal como nos estudos do
impacto do Working Capital, o Ciclo de Conversão de Caixa tem uma relação negativa com
o rendimento e tem bastante impacto. Desta tabela retira-se também a informação que o
DIO é importante para o rendimento e quanto menor for este valor, maior será o rendimento.
Por outro lado, o DPO tem uma correlação positiva com o rendimento, mas não tem tanto
impacto sobre este.

Resultados da correlação de Pearson (cont.)				
Variáveis	Itália		Portugal	
	Pearson (<i>r</i>)	Significância (<i>p</i>)	Pearson (<i>r</i>)	Significância (<i>p</i>)
CCC	0.01	0.9	0.28	0.04
DPO	0	0.99	-0.24	0.08
DIO	-0.13	0.22	0	0.98
DSO	0.25	0.02	0.17	0.2
OC	0.03	0.78	0.11	0.42

Tabela 17: Resultados da correlação de Pearson entre as variáveis do Working Capital e a rentabilidade (cont.)

Resultados da correlação de Pearson - Global		
Variáveis	Pearson (<i>r</i>)	Significância (<i>p</i>)
CCC	-0.47	0
DPO	0.19	0
DIO	-0.35	0
DSO	0.1	0.02
OC	-0.27	0

Tabela 18: Resultados da correlação de Pearson entre as variáveis do Working Capital e a rentabilidade - resultados globais

As primeiras cinco hipóteses propostas para este estudo centram-se em torno da corre-
lação das variáveis do Working Capital e o Resultado Operacional Bruto. Estas hipóteses
foram testadas nas empresas vitivinícolas de Espanha, França, Itália e Portugal. Neste es-
tudo as hipóteses **h1** a **h5** foram comprovadas para todas as variáveis no âmbito global (ta-
bela 20), no entanto, analisando cada país, apenas foram encontradas correlações relevantes
para o CCC das empresas portuguesas e DSO das empresas italianas. Na tabela 19 estão os
resultados das diferentes hipóteses, distribuídas pelos diferentes países.

A hipótese h1 (Existe uma correlação entre o Ciclo de Conversão de Caixa e a rentabi-
lidade das empresas) não foi comprovada nas empresas espanholas, francesas e italianas. O
resultado da correlação de Pearson das empresas portuguesas mostra que existe uma correla-
ção positiva entre o CCC e a rentabilidade e esta é comprovada pela significância $p = 0.04$.
Para as empresas espanholas a correlação com o rendimento é quase nula e a significân-
cia muito alta. Isto mostra que correlação não é relevante para afetar o rendimento. Para

as empresas francesas a correlação mostra um resultado negativo com uma significância de $p = 0.1$. No caso das empresas italianas, a correlação é nula $r = 0.01$ com uma significância $p = 0.9$. No âmbito global (alínea e), ou seja, utilizar os dados de todas as empresas e não agrupa-las por país, a correlação é negativa e alta $r = -0.47$ com uma significância perfeita $p = 0$. Isto mostra que na perspetiva global das empresas vitivinícolas, a gestão do Ciclo de Conversão de Caixa é muito relevante para a rentabilidade e quanto maior for este valor, menor será a rentabilidade.

A hipótese h2 (Existe uma correlação entre o Prazo Médio de Pagamento e a rentabilidade das empresas) não foi comprovada para nenhum dos países (alínea a a d). Para as empresas espanholas, francesas e italianas, a correlação mostra-se nula ou quase nula, com altos valores de significância $p \geq 0.05$. Para as empresas portuguesas a correlação é negativa $r = -0.24$, mas a significância ultrapassa o valor aceitável. No âmbito global (alínea e) esta hipótese foi comprovada $p = 0$ e tem uma correlação de $r = 0.19$. Nesta perspetiva, quanto maior for o DPO, maior será a rentabilidade das empresas.

A hipótese h3 (Existe uma correlação entre o Prazo Médio de Recebimento e a rentabilidade das empresas) não foi comprovada para as empresas espanholas, francesas e portuguesas. A correlação entre o DSO e a rentabilidade das empresas italianas é positiva $r = 0.25$ com uma significância de $p = 0.02$. Este resultado representa que para as empresas italianas, quanto maior for o Prazo Médio de Recebimento, maior será a rentabilidade. Na perspetiva global (alínea e), a correlação é positiva $r = 0.1$ e é significativa $p = 0.02$.

A hipótese h4 (Existe uma correlação entre o Prazo Médio de Rotação de Inventário e a rentabilidade das empresas) não foi comprovada para nenhum dos países individualmente. Nesta correlação, as empresas francesas mostram uma significância de $p = 0.07$, que ultrapassa o limite aceitável de $p \leq 0.05$. Para a totalidade das empresas vitivinícolas, a correlação mostra existe uma relação negativa entre o DIO e a rentabilidade $r = -0.35$ com uma significância de $p = 0$.

A hipótese h5 (Existe uma correlação entre o Ciclo Operacional e a rentabilidade das empresas) não foi comprovada para as empresas espanholas, italianas e portuguesas. No caso das empresas francesas, estas apresentam uma correlação negativa entre o OC e a rentabilidade $r = -0.19$ e uma significância de $p = 0.03$. Isto significa que quanto maior for o Ciclo Operacional, menor será a rentabilidade. No âmbito global (alínea e), as empresas apresentam uma correlação negativa de $r = -0.27$ e uma significância de $p = 0$.

Teste das Hipóteses				
Hipótese	a	b	c	d
h1	N/ Comprovada	N/ Comprovada	N/ Comprovada	Comprovada
h2	N/ Comprovada	N/ Comprovada	N/ Comprovada	N/ Comprovada
h3	N/ Comprovada	N/ Comprovada	Comprovada	N/ Comprovada
h4	N/ Comprovada	N/ Comprovada	N/ Comprovada	N/ Comprovada
h5	N/ Comprovada	Comprovada	N/ Comprovada	N/ Comprovada

Tabela 19: Teste das Hipóteses **h1** a **h5**

Teste das Hipóteses	
Hipótese	e
h1	Comprovada
h2	Comprovada
h3	Comprovada
h4	Comprovada
h5	Comprovada

Tabela 20: Teste das Hipóteses **h1** a **h5** - resultados globais

4.5 Rede Neuronal Artificial

A rede neuronal utilizada neste estudo é composta por um *layer* de entrada que aceita 5 variáveis: Ciclo de Conversão de Caixa, Ciclo Operacional, Prazo Médio de Pagamento, Prazo Médio de Recebimento e Prazo Médio de Rotação de Inventário, por 2 *layers* intermédios que transformam os *inputs* e um *output layer* que tenta aproximar a previsão ao resultado esperado, neste caso o Resultado Operacional Bruto. Cada *layer* intermédio é composto por 16 neurónios que atribuem aleatoriamente diferentes pesos a cada *input*. Na figura 27 está representado o esquema desta rede neuronal.

Após a filtragem dos dados obtidos restaram 324 empresas e 521 anos empresariais para serem analisados. Na figura 28 está representada a dispersão do Ciclo de Conversão de Caixa pelo EBITDA. Esta figura mostra que não existe uma relação linear entre o número de dias de CCC e a rentabilidade de uma empresa. As redes neuronais têm a capacidade de avaliar dados não lineares e espera-se que esta rede em particular consiga encontrar uma relação entre as variáveis do WCM e a rentabilidade das empresas.

Esta rede neuronal foi treinada várias vezes com parâmetros diferentes durante Iteração do algoritmo de aprendizagem variáveis e o desempenho da sua aprendizagem é demonstrado pela evolução das Loss Functions, representadas na figura 29. A rede foi testada com 50 Epochs, 100, 200, 500, 1000, 2000 e 3000, mas a partir dos 200 Epochs não existe uma melhoria significativa no seu desempenho. A rede neuronal final foi treinada durante 200 Iteração do algoritmo de aprendizagem. Esta rede neuronal teve como aprendizagem 417

dados (training-set), 52 dados como validation-set e 52 dados como test-set.




Figura 27: Estrutura da Rede Neuronal




Figura 28: Dispersão do Ciclo de Conversão de Caixa pelo EBITDA

Na figura 29 estão representados três gráficos com três Loss Functions diferentes. O primeiro gráfico (Loss Function Mean Squared Error) mostra a função de custo utilizada para

avaliar a rede durante os vários Epochs. O segundo (Loss Function Mean Absolute Error) e o terceiro gráfico (Loss Function Mean Squared Logarithmic Error) foram utilizados para testar qual seria a função de custo com melhor desempenho. Nesta rede, a função de custo com melhor desempenho foi a função erro quadrático médio (Mean Squared Error) - equação 3.11.

O resultado da aprendizagem da rede neuronal está representado na figura 30, que mostra a comparação da tendência do valor previsto (linha cor-de-rosa) com a tendência do valor esperado (linha azul) - valores normalizados do EBITDA. O valor previsto é o valor obtido através da rede e o valor esperado é o valor real de uma empresa escolhida aleatoriamente. Neste gráfico, o melhor resultado possível seria a sobreposição das duas linhas, isto significaria que a rede consegue atingir o resultado esperado com precisão. No entanto, isto não acontece. Como é possível verificar, existem diferenças no valor previsto, mas este consegue seguir a tendência do resultado real, ou seja, quando o valor esperado sobe, o valor previsto também sobe, só que não na mesma proporção.

Na figura 31 está representado o mesmo resultado da figura anterior, mas desta vez num gráfico de barras para podermos analisar o desvio do valor previsto. Como se pode verificar, a rede neuronal não consegue prever com exatidão o valor do EBITDA dado as variáveis do Working Capital. A diferença para a maior parte dos casos não é elevada, mas não é zero.

Dados estes resultados a hipótese **h6** é comprovada e a hipótese **h7** não é comprovada. Apesar de existir pouca diferença entre o valor previsto e valor esperado, esta diferença torna-se significativa na fiabilidade da rede. Isto é, não é possível ter certeza se o resultado previsto irá representar a realidade ou não. No entanto, o gráfico da tendência mostra-nos, dados determinados *inputs*, se o Resultado Operacional Bruto vai aumentar ou diminuir, o que representa uma grande ajuda na gestão das variáveis do Working Capital.

De forma a fazer-se previsões do resultado para determinados *inputs* nesta rede neuronal, é necessário utilizar as seguintes fórmulas com os respetivos pesos descritos nas tabelas 31, 32, 33, 34, 35 e 36, e respetivos *bias* nas tabelas 37, 38 e 39 do apêndice.

Resultados dos neurónios da primeira camada intermédia:

$$x = \sum_{n=1}^n [i_n w_n + b] \quad (4.1)$$

Onde:

x = Resultado do neurónio

i = Valor do input i

w = Peso do input i

b = *Bias* do neurónio x

n = Número de inputs

Resultados dos neurónios da segunda camada intermédia:

$$y = \sum_{n=1}^n [x_i w_i + b] \quad (4.2)$$

Onde:

y = Resultado do neurónio

x = Valor do neurónio x

w = Peso do neurónio x

b = *Bias* do neurónio y

n = Número de neurónios da camada anterior

Resultado do neurónio da camada de saída:

$$p = \sum_{n=1}^n [y_i w_i + b] \quad (4.3)$$

Onde:

p = Output

y = Valor do neurónio y

w = Peso do neurónio y

b = *Bias* do neurónio p

n = Número de neurónios da camada anterior

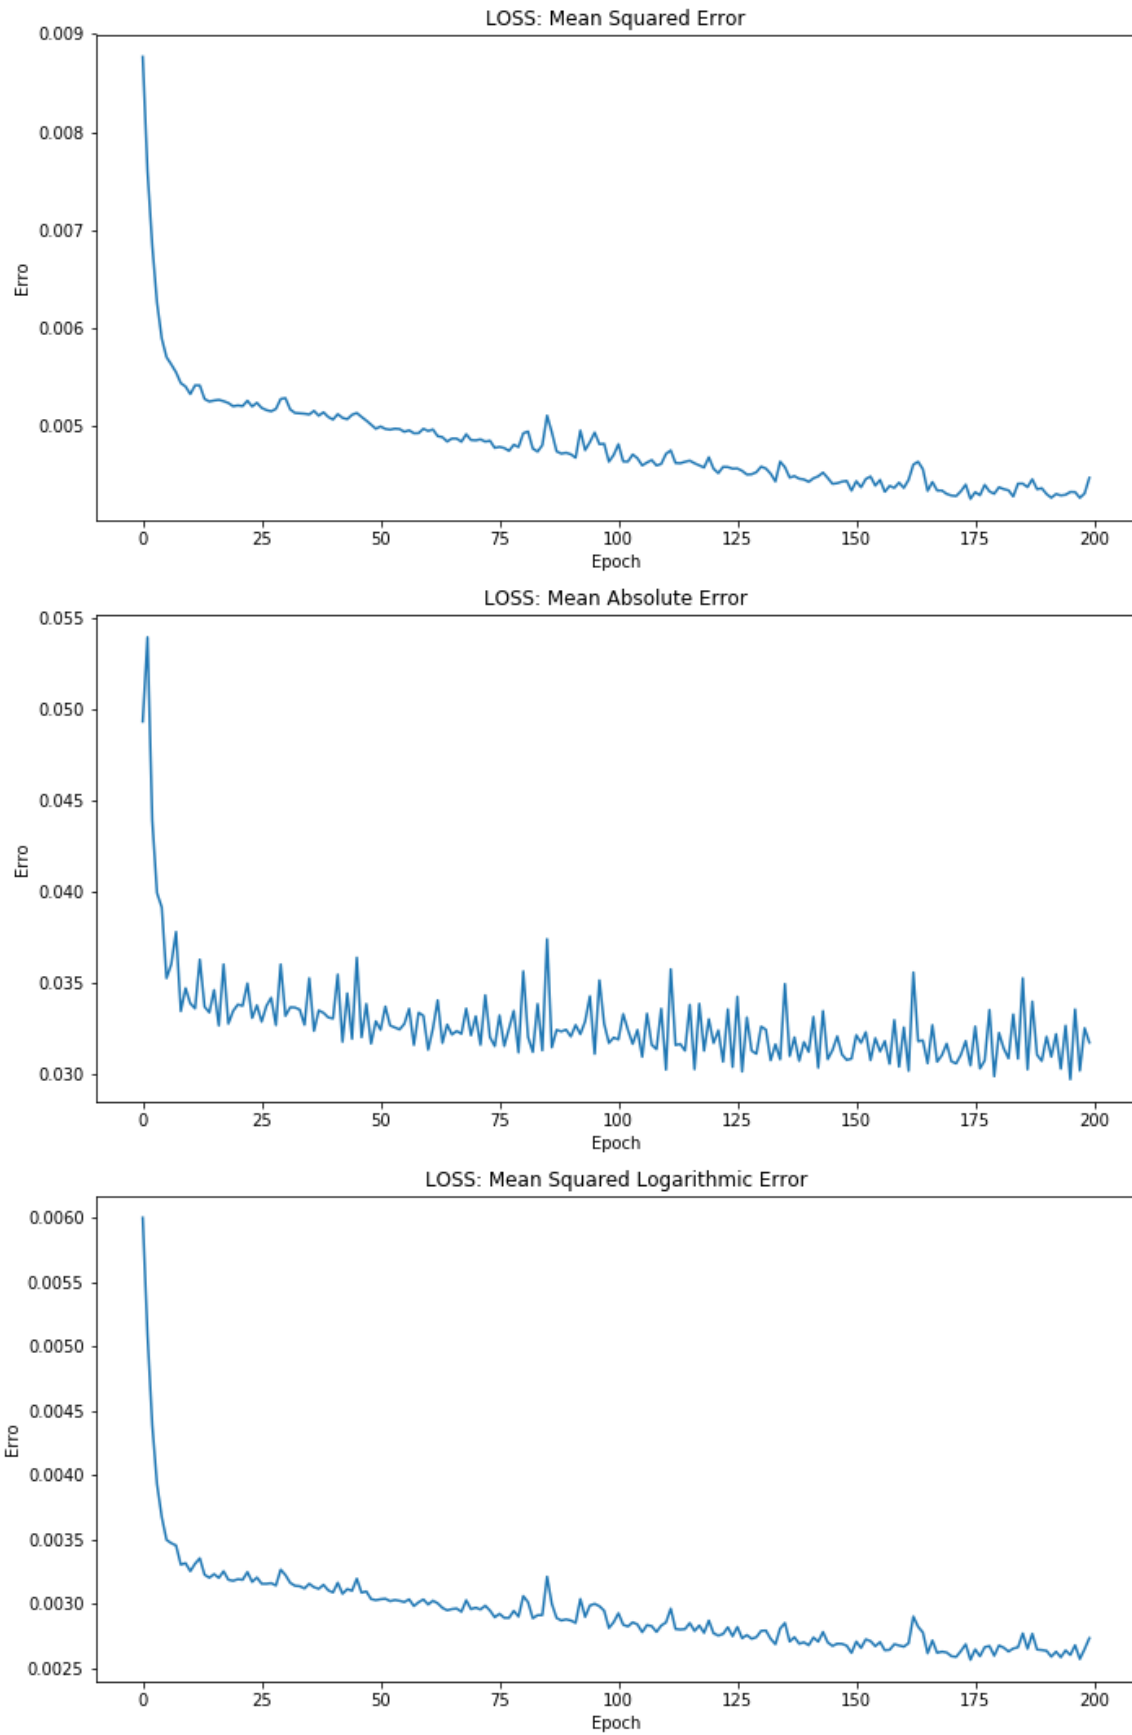


Figura 29: Evolução da aprendizagem da rede neuronal




Figura 30: Resultados da rede neuronal artificial - tendência

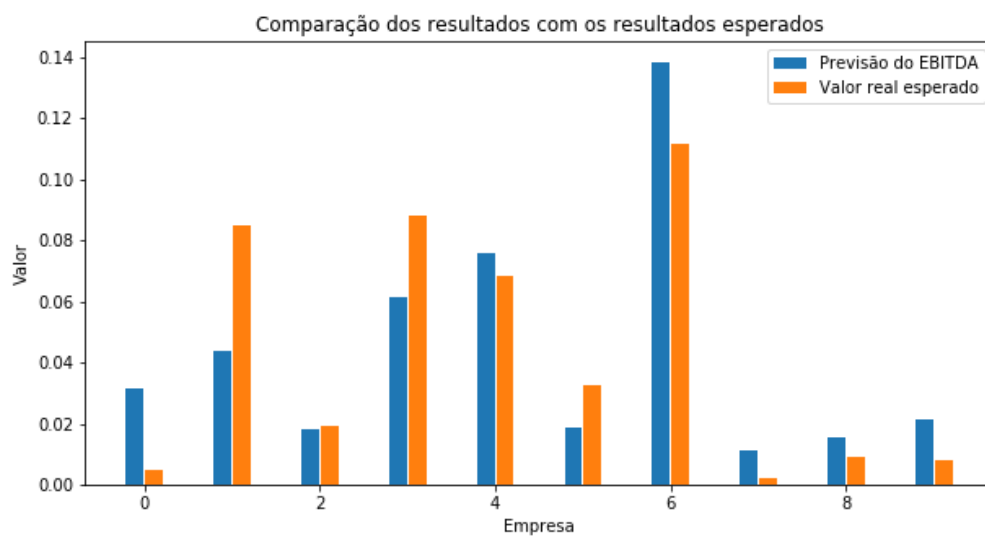


Figura 31: Resultados da rede neuronal artificial - valor

Capítulo V

Conclusão

Diversos autores encontraram relações entre o Working Capital, neste caso o Ciclo de Conversão de Caixa, e a rentabilidade das empresas. Deloof (2003) e Lazaridis (2006) encontraram que existe uma relação entre estas variáveis para as empresas belgas e para as empresas gregas respetivamente. No estudo da relação do WCM e a rentabilidade das empresas turcas de Uyar (2009), o autor conclui que existe uma relação negativa entre estas variáveis.

As empresas de diferentes setores são afetadas de formas diferentes pelo CCC e nestes estudos foram analisadas empresas do setor industrial. As empresas do setor vitivinícola são também afetadas pela gestão das variáveis do CCC, mas é necessário saber qual a relação que existe e o seu impacto na rentabilidade.

O objetivo deste estudo é encontrar a relação entre o Working Capital e o Resultado Operacional Bruto das empresas vitivinícolas de Portugal, Espanha, França e Itália. Para tal, foram analisadas 324 empresas e 521 anos empresariais através da correlação de Pearson e de uma rede neuronal artificial.

Neste estudo foram comprovadas as hipóteses globais que retratam a correlação das variáveis do Ciclo de Conversão de Caixa e a rentabilidade das empresas, enquanto que apenas algumas hipóteses individuais de cada país foram comprovadas. Isto significa que as empresas de cada país têm uma forma diferente de gerir o WCM. E essa forma tem diferentes resultados.

Para o caso das empresas francesas, cuja correlação do Ciclo Operacional com o EBITDA, os resultados assemelham-se aos resultados obtidos pelos autores Deloof (2003), Lazaridis (2006), Uyar (2009). Neste caso, existe uma correlação negativa em que quanto maior for o OC, menor será o rendimento. Por outro lado, para as empresas portuguesas o resultado

observado é contrário ao destes autores. A correlação do Ciclo de Conversão de Caixa com o Resultado Operacional Bruto é positiva. Nos estudos do WCM de Russo (2013) e Serrasqueiro (2014), não foram encontradas relações entre as variáveis para as pequenas e médias empresas e empresas registadas na base “Bloomberg” respetivamente. Isto significa que as empresas vitivinícolas portuguesas operam de forma diferente de outros tipos de empresas.

No âmbito global, este estudo vai de encontro aos resultados obtidos por Deloof (2003), Lazaridis (2006) e Uyar (2009). A correlação do CCC com o EBITDA é negativo $r = -0.47$ com uma significância $r = 0$. Isto significa que quanto maior o Ciclo de Conversão de Caixa, menor será a rentabilidade. E de acordo com estes autores, isto faz sentido, pois se a empresa tem o seu capital empatado durante mais tempo, terá menos facilidade de fazer face aos seus custos.

Tal como no estudo de Serrasqueiro (2014), a correlação do Prazo Médio de Rotação de Inventário com a rentabilidade é negativa, sendo que quanto maior for o número de dias da matéria-prima em inventário, menor será a rentabilidade. E neste mesmo estudo foi também concluído que a correlação do Prazo Médio de Pagamento com o EBITDA é positiva e significativa $r = 0.19$. No estudo de Russo (2013) foi também encontrada uma correlação negativa do WCM e a rentabilidade, que vai de acordo com os resultados obtidos neste estudo.

As metodologias de análise dos dados deste estudo não são de carácter eliminatório, ou seja, não é o caso de se ou aceitar a correlação de Pearson, ou aceitar a análise da rede neuronal artificial. Estas duas metodologias são complementares e devem ser usadas em conjunto para se poder tomar uma melhor decisão. Enquanto que as correlações de Pearson indicam-nos o impacto geral das variáveis do Working Capital na rentabilidade, a rede neuronal artificial indica-nos se irá haver uma melhoria da rentabilidade após uma alteração das variáveis. Estas duas metodologias tornam-se fundamentais para a tomada de decisão, pois não só se analisa se o impacto é negativo ou positivo, mas como também até onde chegará a rentabilidade, dentro de uma margem de erro.

Apesar dos resultados serem satisfatórios no caso das perspetivas globais das correlações e da aproximação à realidade por parte da rede neuronal, este estudo pode ser melhorado através de outra metodologia de remoção de *outliers*. Os *outliers* presentes nestes dados foram responsáveis pela não inclusão de uma grande parte das empresas do total de dados obtidos. Havendo outra forma de fazer a seleção dos dados, mais hipóteses poderão ser comprovadas e a rede neuronal artificial melhorada.

Bibliografia (Norma APA)

- Ali, W. e Hassan, S. H. U. (2010). Relationship between the profitability and working capital policy of swedish companies. Tese de Mestrado, Umea School of Business.
- Anderson, K., Nelgen, S., e Pinilla, V. (2016). *Global Wine Markets, 1961 to 2009: A Statistical Compendium*. University of Adelaide Press.
- Anderson, K., Nelgen, S., e Pinilla, V. (2017). Global wine markets, 1860 to 2016: A statistical compendium. *University of Adelaide Press*.
- Anderson, K. e Wittwer, G. (2013). Modeling global wine markets to 2018: Exchange rates, taste changes, and china's import growth. *Journal of Wine Economics*, 8(2):131–158.
- Anderson, K. e Wittwer, G. (2017). U.k. and global wine markets by 2025, and implications of brexit. *Journal of Wine Economics*, 12(3):221–251.
- Bengio, Y. (2013). Artificial neural networks: How can i estimate the number of neurons and layers? Quora. Head of Montreal Institute for Learning Algorithms.
- Brealey, R. A., Myers, S. C., e Allen, F. (2006). *Principles of corporate finance*. McGraw-Hill/Irwin.
- Ching, H. Y., Novazzi, A., e Gerab, F. (2011). Relationship between working capital management and profitability in brazilian listed companies. *Journal of Global Business and Economics*, 3(1):74–86.
- Cholette, S., Castaldi, R. M., e Fredrick, A. (2005). The globalization of the wine industry: Implications for old and new world producers. *International Business and Economy Conference Proceedings*.
- Cortez, P. e Neves, J. (2000). *Redes Neuronalis Artificias*. Universidade do Minho. Apontamentos de apoio à disciplina de Sistemas Inteligentes.
- Deloof, M. (2003). Does working capital management affect profitability of belgian firms. *Journal of Business Finance & Accounting*, 30(3):573–587.

- Emery, G. W. (1984). A pure financial explanation for trade credit. *Journal of Financial and Quantitative Analysis*, 9(3):271–285.
- Filbeck, G. e Krueger, T. M. (2005). An analysis of working capital management results across industries. *American Journal of Business*, 20(2):11–20.
- Garg, A. K. e Gumbochuma, M. I. (2015). Relationship between working capital management and profitability in jse listed retail sector companies. *Investment Management and Financial Innovations*, 12(2):127–135.
- Gelman, A. e Hill, J. (2007). Data analysis using regression and multilevel/hierarchical models. Technical report, Cambridge University Press.
- Gilbert, E. e Reichert, A. (1995). The practice of financial management among large united states corporations. *Financial Practice and Education*, 25(1):16–23.
- Gill, A., Biger, N., e Mathur, N. (2010). The relationship between working capital management and profitability: Evidence from the united states. *Business and Economics Journal*, 2010(BEJ-10):1–9.
- Goodfellow, I., Bengio, Y., e Courville, A. (2016). *Deep Learning*. MIT Press. <http://www.deeplearningbook.org>.
- Hahnloser, R., Sarpeshkar, R., Mahowald, M. A., Douglas, R. J., e Seung, H. (2000). Digital selection and analogue amplification coexist in a cortex-inspired silicon circuit. *Nature*, 405:947–951.
- Hawawini, G., Viallet, C., e Vora, A. (1986). Industry influence on corporate working capital decisions. *Sloan Management Review*, 27(4):15–24.
- International Organization of Vine and Wine (2017). 2017 world vitiviniculture situation. *OIV Statistical Report on World Vitiviniculture*.
- International Organization of Vine and Wine (2018). State of the vitiviniculture world market. *International Organization of Vine and Wine*.
- Keown, A. J., Martin, J. D., Petty, J. W., e Scott, D. F. (2003). *Foundations of Finance*. Pearson Education, New Jersey, 4 edition.
- Lazaridis, I. (2006). The relationship between working capital management and profitability of listed companies in the athens stock exchange. *Journal of Financial Management and Analysis*, 19(1):1–12.
- Lohr, S. L. (1999). *Sampling: Design and Analysis*. Duxbury Press.

- Padachi, K. (2006). Trends in working capital management and its impact on firms' performance: An analysis of mauritian small manufacturing firms. *International Review of Business Research Papers*, 2(2):45–58.
- Plant, A. C. (2007). *The retail game: Playing to win: a guide to the profitable sale of goods and services*. Douglas and McIntyre Ltd.
- Prat, J. (2003). *Financial Accounting in an Economic Context*. John Wiley and Sons.
- Preve, L. A. e Sarria-Allende, V. (2010). *Working Capital Management*. Oxford University Press.
- Raheman, A. e Nasr, M. (2007). Working capital management and profitability – case of pakistani firms. *International Review of Business Research Papers*, 3(1):279–300.
- Rehn, E. (2012). Effects of working capital management on company profitability: An industry-wise study of finish and swedish public companies. Tese de Mestrado, Hanken School of Economics.
- Reitermanová, Z. (2010). Data splitting. *WDS*.
- Richards, V. D. e Laughlin, E. J. (1980). A cash conversion cycle approach to liquidity analysis. *Financial Management*, 9(1):32–38.
- Russo, J. F. T. B. (2013). The working capital management: the determinants and the effect on profitability: evidence from portuguese smes. Tese de Mestrado, ISCTE Business School: Instituto Universitário de Lisboa.
- Schmidhuber, J. (2014). Deep learning in neural networks: An overview. *CoRR*, abs/1404.7828.
- Schwartz, R. A. (1974). An economic model of trade credit. *Journal of Financial and Quantitative Analysis*, 9(4):643–657.
- Serrasqueiro, J. N. (2014). Working capital management impact on profitability: Empirical study based on portuguese firms. Tese de Mestrado, Católica Lisbon School of Business and Economics.
- Shilling, G. (1996). Working capital's role in maintaining corporate liquidity. *AFP Exchange*, 16(5):4–7.
- Shin, H.-H. e Soenen, L. (1998). Efficiency of working capital management and corporate profitability. *Financial Practice and Education*, 8(2):37–45.

- Soenen, L. (1993). Cash conversion cycle and corporate profitability. *AFP Exchange*, 13(4):53.
- Strischek, D. (2002). A banker's perspective on working capital and cash flow management. *Engineering Management Review, IEEE*, 30:76–76.
- Summers, B. e Wilson, N. (2000). Trade credit management and the decision to use factoring: An empirical study. *Journal of Business Finance & Accounting*, 27(1 and 2):37–68.
- Thorpe, M. (2009). The globalisation of the wine industry: new world, old world and china. *China Agricultural Economic Review*, 1(3):301–313.
- Uyar, A. (2009). The relationship of cash conversion cycle with firm size and profitability: An empirical investigation in turkey. *International Research Journal of Finance and Economics*, (2).
- Wilner, B. S. (2000). The exploitation of relationships in financial distress: The case of trade credit. *Journal of Finance*, 55(1):153–158.
- Zhang, J. (2011). The relationship between working capital management and the corporate cash holdings. Tese de Mestrado, University of Eastern Finland.

Apêndice

Dados das empresas vitivinícolas

Variação da média do CCC				
Ano	ES	FR	IT	PT
2005	0	196	0	0
2006	0	210	0	323
2007	0	195	77	263
2008	247	182	93	267
2009	240	204	101	231
2010	260	170	101	276
2011	233	190	84	268
2012	250	174	98	287
2013	248	199	139	315
2014	250	211	121	298
2015	257	200	114	287
2016	253	182	128	304
2017	282	212	163	0

Tabela 21: Variação da média do Ciclo de Conversão de Caixa

Varição da média do DPO				
Ano	ES	FR	IT	PT
2005	0	17	0	0
2006	0	23	0	204
2007	0	33	166	177
2008	109	47	155	216
2009	108	26	165	264
2010	98	51	151	205
2011	114	35	173	193
2012	113	50	156	208
2013	110	26	126	187
2014	95	25	137	185
2015	101	25	152	253
2016	109	34	136	193
2017	103	25	113	0

Tabela 22: Variação da média do Prazo Médio de Pagamento

Varição da média do DIO				
Ano	ES	FR	IT	PT
2005	0	103	0	0
2006	0	172	0	365
2007	0	126	132	255
2008	256	139	133	328
2009	246	143	162	306
2010	258	141	138	309
2011	242	142	147	270
2012	256	136	139	319
2013	255	139	160	315
2014	241	156	150	338
2015	259	136	163	409
2016	261	132	153	332
2017	316	151	162	0

Tabela 23: Variação da média do Prazo Médio de Rotação de Inventário

Varição da média do DSO				
Ano	ES	FR	IT	PT
2005	0	110	0	0
2006	0	61	0	162
2007	0	102	110	185
2008	100	91	115	155
2009	102	87	104	189
2010	100	79	113	173
2011	106	82	110	191
2012	106	89	114	175
2013	104	86	105	187
2014	105	80	108	145
2015	99	90	102	132
2016	101	84	111	166
2017	69	86	113	0

Tabela 24: Variação da média do Prazo Médio de Recebimento

Varição da média do OC				
Ano	ES	FR	IT	PT
2005	0	213	0	0
2006	0	233	0	527
2007	0	228	243	440
2008	356	230	248	483
2009	348	230	266	494
2010	358	220	251	481
2011	347	225	257	461
2012	363	224	254	494
2013	358	225	265	502
2014	345	236	258	483
2015	358	226	266	540
2016	362	216	265	498
2017	386	236	276	0

Tabela 25: Variação da média do Ciclo Operacional

Varição da média do Resultado Operacional Bruto				
Ano	ES	FR	IT	PT
2005	0,00 €	152 539,00 €	0,00 €	0,00 €
2006	0,00 €	134 976,00 €	0,00 €	88 148,00 €
2007	0,00 €	234 913,83 €	531 266,25 €	233 919,67 €
2008	113 424,50 €	221 718,20 €	628 760,33 €	223 476,00 €
2009	135 798,89 €	183 157,00 €	515 737,43 €	324 498,00 €
2010	167 917,54 €	261 513,65 €	496 779,00 €	264 658,63 €
2011	138 425,00 €	195 515,42 €	543 361,45 €	215 852,25 €
2012	173 421,88 €	250 134,64 €	713 355,50 €	318 697,83 €
2013	165 055,74 €	224 770,94 €	704 923,00 €	323 744,20 €
2014	148 015,50 €	274 494,60 €	647 877,00 €	180 364,40 €
2015	138 271,15 €	268 091,33 €	603 309,33 €	222 231,50 €
2016	126 302,16 €	271 749,29 €	803 464,43 €	235 592,56 €
2017	190 053,50 €	210 057,56 €	725 241,33 €	0,00 €

Tabela 26: Variação da média do Resultado Operacional Bruto

Espanha										
Variáveis	Nº dados	Média	Desvio	Mínimo	25%	50%	75%	Máximo		
Conta de Clientes	244	438 417,37 €	315 104,00 €	14 480,00 €	212 584,50 €	368 730,50 €	591 221,75 €	1 858 388,00 €		
Conta de Fornecedores	244	278 137,22 €	247 541,99 €	9 872,00 €	108 393,25 €	200 015,00 €	373 259,50 €	1 543 249,00 €		
Vendas	244	1 589 487,34 €	1 123 185,15 €	77 648,00 €	775 869,50 €	1 333 995,50 €	2 131 653,25 €	9 142 452,00 €		
Compras	244	946 853,00 €	683 799,76 €	40 600,00 €	472 989,25 €	768 276,50 €	1 251 866,25 €	5 734 712,00 €		
EBITDA	244	145 861,03 €	76 860,16 €	27 488,00 €	84 829,25 €	130 407,50 €	189 351,75 €	536 258,00 €		
Rendimento Operacional	244	1 610 502,20 €	1 127 133,17 €	96 240,00 €	791 786,75 €	1 360 599,50 €	2 162 067,00 €	9 142 452,00 €		
Profit Margin	244	2,64	6,46	-33,04	0,42	2,05	4,87	34,03		
Fluxo de Caixa	244	108 801,34 €	48 260,47 €	41 580,00 €	64 695,75 €	104 469,00 €	142 605,00 €	212 510,00 €		
Dívida L/P	244	652 219,88 €	889 919,83 €	0,00 €	79 206,00 €	318 348,50 €	841 102,00 €	5 975 706,00 €		
DPO	244	106	46	12	72	102	143	188		
DIO	244	253	48	142	213	253	288	365		
DSO	244	102	23	61	82	102	121	147		
OC	244	355	47	276	316	355	394	438		
CCC	244	250	64	109	205	248	292	422		

Tabela 27: Estatística das empresas espanholas

França									
Variáveis	Nº dados	Média	Desvio	Mínimo	25%	50%	75%	Máximo	
Conta de Clientes	133	1 071 494,45 €	615 140,53 €	274 555,00 €	594 653,00 €	949 295,00 €	1 332 047,00 €	3 758 257,00 €	
Conta de Fornecedores	133	306 932,48 €	244 142,28 €	54 021,00 €	133 058,00 €	252 229,00 €	389 870,00 €	1 472 147,00 €	
Vendas	133	4 544 775,53 €	2 337 295,50 €	1 381 554,00 €	2 575 466,00 €	4 272 934,00 €	5 972 060,00 €	13 342 543,00 €	
Compras	133	3 307 719,35 €	1 754 774,06 €	985 313,00 €	1 876 850,00 €	3 010 247,00 €	4 416 857,00 €	9 909 431,00 €	
EBITDA	133	240 602,29 €	103 263,66 €	90 909,00 €	163 164,00 €	221 777,00 €	290 771,00 €	619 581,00 €	
Rendimento Operacional	133	4 736 827,05 €	2 397 456,78 €	1 460 327,00 €	2 764 323,00 €	4 216 680,00 €	6 158 310,00 €	13 016 382,00 €	
Profit Margin	133	1,04	2,67	-2,77	0,01	0,28	1,24	16,19	
Fluxo de Caixa	133	219 073,89 €	79 450,63 €	112 213,00 €	145 399,00 €	203 022,00 €	284 550,00 €	375 585,00 €	
Dívida L/P	133	1 251 633,74 €	2 390 540,70 €	0,00 €	173 908,00 €	355 370,00 €	1 160 636,00 €	19 370 285,00 €	
DPO	133	36	23	13	19	26	42	105	
DIO	133	140	26	92	122	139	159	198	
DSO	133	86	16	54	73	85	100	113	
OC	133	225	19	193	209	222	244	257	
CCC	133	190	31	90	175	195	211	236	

Tabela 28: Estatística das empresas francesas

Italia										
Variáveis	Nº dados	Média	Desvio	Mínimo	25%	50%	75%	Máximo		
Conta de Clientes	88	3 479 762,38 €	3 047 553,76 €	400 429,00 €	1 784 947,75 €	2 732 291,50 €	3 966 463,00 €	22 956 744,00 €		
Conta de Fornecedores	88	3 297 775,73 €	2 780 300,91 €	245 599,00 €	1 585 334,25 €	2 530 366,50 €	4 124 275,25 €	20 670 937,00 €		
Vendas	88	11 639 683,88 €	9 637 122,45 €	1 519 226,00 €	6 280 508,50 €	9 126 225,00 €	14 141 498,50 €	64 148 910,00 €		
Compras	88	8 248 949,55 €	6 893 518,61 €	1 044 057,00 €	4 406 280,25 €	6 303 112,50 €	9 902 319,50 €	48 748 677,00 €		
EBITDA	88	626 172,65 €	259 526,35 €	226 173,00 €	435 772,00 €	570 992,50 €	802 238,25 €	1 581 659,00 €		
Rendimento Operacional	88	11 903 471,24 €	9 870 453,14 €	1 743 478,00 €	6 350 815,50 €	9 123 750,00 €	14 256 449,75 €	66 402 318,00 €		
Profit Margin	88	2,61	4,24	-0,57	0,29	1,14	2,64	25,78		
Fluxo de Caixa	88	410 911,27 €	146 003,73 €	189 826,00 €	286 913,75 €	396 194,50 €	534 681,00 €	686 222,00 €		
Dívida L/P	88	1 293 722,77 €	1 537 566,68 €	0,00 €	145 833,25 €	779 190,50 €	1 644 334,50 €	7 260 810,00 €		
DPO	88	150	45	58	123	150	181	236		
DIO	88	150	26	98	129	152	167	203		
DSO	88	109	16	79	94	112	123	135		
OC	88	259	20	220	243	260	276	294		
CCC	88	109	49	-4	74	111	140	208		

Tabela 29: Estatística das empresas italianas

Portugal										
Variáveis	Nº dados	Média	Desvio	Mínimo	25%	50%	75%	Máximo		
Conta de Clientes	56	904 397,20 €	940 571,18 €	71 782,00 €	365 797,75 €	572 247,50 €	1 000 202,00 €	4 438 498,00 €		
Conta de Fornecedores	56	559 398,55 €	542 960,12 €	45 989,00 €	206 014,00 €	362 718,00 €	712 843,50 €	2 495 524,00 €		
Vendas	56	1 853 048,91 €	1 624 197,10 €	166 884,00 €	861 088,00 €	1 463 156,00 €	2 021 940,00 €	7 044 192,00 €		
Compras	56	1 031 394,82 €	981 484,43 €	92 346,00 €	437 674,75 €	763 405,00 €	1 079 541,00 €	4 115 960,00 €		
EBITDA	56	247 532,66 €	144 758,52 €	64 165,00 €	143 322,25 €	219 710,00 €	343 927,25 €	816 293,00 €		
Rendimento Operacional	56	1 968 279,57 €	1 578 912,76 €	263 593,00 €	973 326,75 €	1 521 773,00 €	2 344 868,00 €	7 211 117,00 €		
Profit Margin	56	3,18	4,91	-12,51	0,66	2,31	6,14	17,91		
Fluxo de Caixa	56	164 165,16 €	82 515,85 €	56 313,00 €	87 198,25 €	151 980,50 €	240 273,50 €	317 508,00 €		
Dívida L/P	56	1 549 232,84 €	1 577 340,12 €	0,00 €	441 456,75 €	960 754,50 €	2 799 728,00 €	6 838 940,00 €		
DPO	56	202	61	102	147	202	248	328		
DIO	56	320	71	180	285	326	369	455		
DSO	56	168	35	105	141	161	199	233		
OC	56	488	54	391	450	490	528	588		
CCC	56	285	74	126	224	296	344	436		

Tabela 30: Estatística das empresas portuguesas

Tabelas de Pesos da Rede Neuronal

	Pesos do Primeiro Layer				
	Input 1	Input 2	Input 3	Input 4	Input 5
Neurônio 1	0.123899571597576	0.125645935535431	-0.071820452809334	-7.616962102247464E-05	0.042695388197899
Neurônio 2	0.034207336604595	-0.116897746920586	0.007178018800914	-0.018709884956479	-0.032191637903452
Neurônio 3	0.193460613489151	-0.008143582381308	-0.081717155873776	0.115788623690605	0.040818642824888
Neurônio 4	-0.143783867359161	-0.110008642077446	0.149095594882965	0.157633364200592	0.321336925029755
Neurônio 5	-0.134929463267326	0.08552011847496	0.091748282313347	-0.067131690680981	0.010890560224652
Neurônio 6	0.071500808000565	0.027792813256383	-0.102718509733677	0.125322625041008	0.067091181874275
Neurônio 7	-0.323289960622787	0.004490176215768	0.14321805536747	-0.099276527762413	-0.051631569862366
Neurônio 8	0.045563142746687	0.0727035105222843	0.045018412172794	0.16523240506649	0.123329117894173
Neurônio 9	0.16762387752533	0.085056081414223	-0.059136413037777	0.140482783317566	0.123644970357418
Neurônio 10	-0.173559486865997	0.013997474685311	0.063059620559216	-0.03431286290288	0.003586398204789
Neurônio 11	0.207600221037865	-0.258751899003982	-0.079320505261421	0.07362312823534	0.005562129896134
Neurônio 12	0.071497447788715	0.087298683822155	-0.079226233065128	0.069828271865845	0.000344278523698
Neurônio 13	0.139168068766594	0.036308631300926	0.015386953018606	0.188740372657776	0.086424149572849
Neurônio 14	0.106452889740467	0.071810454130173	-0.033364675939083	0.110713690519333	0.136770486831665
Neurônio 15	-0.226369574666023	0.173284962773323	-0.044478084892035	0.155142843723297	0.127596899867058
Neurônio 16	0.0317252227832794	-0.003633656073362	-0.024267105385661	-0.070153668522835	-0.005911593791097

Tabela 31: Pesos do Primeiro Layer

Pesos do Segundo Layer				
	Primeiro Layer – Neurônio 1	Primeiro Layer – Neurônio 2	Primeiro Layer – Neurônio 3	Primeiro Layer – Neurônio 4
Neurônio 1	0.0807850733399391	-0.0121180359274149	0.135478883981705	-0.655247926712036
Neurônio 2	0.0624263025820255	-0.0300821531563997	0.0362239219248295	-0.271262109279633
Neurônio 3	0.0608033053576946	0.064865380525589	0.116802781820297	-0.468240767717361
Neurônio 4	-0.00533564854413271	0.0806763917207718	-0.00947402603924274	0.0583344511687756
Neurônio 5	-0.0350064560770988	0.0352182798087597	-0.0625763162970543	0.0150151578709483
Neurônio 6	-0.0023528328165412	0.00340006570331752	-0.00434123724699021	-0.012318548746407
Neurônio 7	0.00661023939028382	0.121203131973743	-0.0454108938574791	0.00879868399351835
Neurônio 8	0.0722319334745407	0.0236460976302624	0.144960641860962	-0.61875593662262
Neurônio 9	-0.0359262488782406	0.0198491625487804	-0.030483141541481	-0.0195076297968626
Neurônio 10	-0.000199498215806671	0.0402070134878159	0.129592478275299	0.0392847321927547
Neurônio 11	0.0852213054895401	0.0374285504221916	0.104343429207802	-0.321793377399445
Neurônio 12	0.0461512804031372	-0.0359488464891911	0.0737168118357658	-0.503214478492737
Neurônio 13	0.00853703636676073	-0.0291314609348774	0.0192808173596859	0.00575173646211624
Neurônio 14	0.0261252224445343	0.0382758118212223	0.0273923203349113	-0.0969580933451653
Neurônio 15	0.0434748269617558	-0.0662299320101738	-0.101662933826446	0.100173234939575
Neurônio 16	-0.00258611352182925	-0.050522081553936	0.0488681010901928	-0.132727429270744

Tabela 32: Pesos do Segundo Layer

Pesos do Segundo Layer (cont.)							
	Primeiro Layer – Neurônio 5	Primeiro Layer – Neurônio 6	Primeiro Layer – Neurônio 7	Primeiro Layer – Neurônio 8			
Neurônio 1	-0.128369733691215	0.143164932727814	0.177221044898033	0.0407160446047783			
Neurônio 2	-0.0411030538380146	0.0993503332138062	-0.0045612733811401	0.140926480293274			
Neurônio 3	-0.0532953441143036	0.0881436616182327	0.132023110985756	0.0760543495416641			
Neurônio 4	-0.0268563814461231	-0.0563945434987545	0.00790108833462	0.0150409797206521			
Neurônio 5	0.0290184747427702	0.0217018984258175	-0.0392134822905064	0.00114265701267868			
Neurônio 6	-0.00818418245762587	-0.0148135321214795	0.0320739559829235	0.00626886449754238			
Neurônio 7	0.011772071942687	0.0427485778927803	-0.0366214849054813	-0.0788116157054901			
Neurônio 8	-0.103301748633385	0.122048608958721	0.160307362675667	0.117781110107899			
Neurônio 9	0.115849904716015	-0.0392085127532482	-0.0183870047330856	-0.0903798192739487			
Neurônio 10	-0.0482250861823559	0.0059815663844347	0.00365190673619509	-0.0308488924056292			
Neurônio 11	-0.135009974241257	0.141040131449699	0.115818336606026	0.0804177224636078			
Neurônio 12	-0.0285583604127169	0.0245523527264595	0.179306074976921	0.0197073444724083			
Neurônio 13	-0.0623375065624714	-0.0256898794323206	0.0271159615367651	-0.0072969370521605			
Neurônio 14	0.0113180186599493	0.09222095403075218	0.0914095565676689	0.0473521687090397			
Neurônio 15	0.0259898956865072	-0.0513406880199909	-0.0877245888113976	0.0476945601403713			
Neurônio 16	0.0177758280187845	-0.00509294774383307	0.162551999092102	0.131020933389664			

Tabela 33: Pesos do Segundo Layer (cont.)

	Pesos do Segundo Layer (cont.)					
	Primeiro Layer – Neurônio 9	Primeiro Layer – Neurônio 10	Primeiro Layer – Neurônio 11	Primeiro Layer – Neurônio 12		
Neurônio 1	0.162092670798302	-0.0639184042811394	-0.234008461236954	0.0331739261746407		
Neurônio 2	0.148914992809296	-0.0567907691001892	-0.483137726783752	0.157365769147873		
Neurônio 3	0.102558895945549	-0.0416037477552891	-0.124409765005112	0.0608615465462208		
Neurônio 4	0.0141752446070314	-0.0611192397773266	-0.0487827062606812	-0.0775800868868828		
Neurônio 5	0.0319054573774338	0.0259925238788128	0.0234159119427204	-0.0737395212054253		
Neurônio 6	0.0065802619792521	-0.0453379042446613	-0.0572815388441086	-0.0232647638767958		
Neurônio 7	-0.00776556646451354	-0.0698356181383133	0.0241989139467478	-0.0392160303890705		
Neurônio 8	0.177783146500587	-0.222589179873466	-0.245846778154373	0.055353868752718		
Neurônio 9	-0.0649250596761704	-0.0545943267643452	0.00438395328819752	-0.035602580755949		
Neurônio 10	0.156433239579201	-0.12454017996788	0.061078954488039	0.0456686392426491		
Neurônio 11	0.124871663749218	-0.0986959412693978	-0.521089494228363	0.137671038508415		
Neurônio 12	0.104433149099935	-0.181675955653191	-0.176229938864708	0.165581285953522		
Neurônio 13	-0.0512947663664818	0.0528010614216328	-0.0673690512776375	-0.0275457836687565		
Neurônio 14	0.0973763465881348	-0.0169111359864473	-0.250840365886688	0.0254735313355923		
Neurônio 15	-0.120509132742882	0.0205571036785841	0.134747669100761	0.0135578541085124		
Neurônio 16	0.192008972167969	-0.08210423558875275	-0.0813880115747452	0.0428017675876617		

Tabela 34: Pesos do Segundo Layer (cont.)

	Pesos do Segundo Layer (cont.)					
	Primeiro Layer – Neurônio 13	Primeiro Layer – Neurônio 14	Primeiro Layer – Neurônio 15	Primeiro Layer – Neurônio 16		
Neurônio 1	0.0783433839678764	0.17336668074131	-0.675118386745453	-0.0218551903963089		
Neurônio 2	0.0765323266386986	0.0990766659379005	-0.158285692334175	0.0522419437766075		
Neurônio 3	0.0806969106197357	0.123945020139217	-0.591042637825012	0.0320093743503094		
Neurônio 4	-0.0776334926486015	0.0416768044233322	-0.0519532673060894	0.0487101674079895		
Neurônio 5	-0.0196337271481752	0.00660568289458752	-0.080473817884922	0.0381200313568115		
Neurônio 6	-0.0245059821754694	-0.00832391809672117	-0.0107891457155347	-0.0209516119211912		
Neurônio 7	-0.0801993235945702	-0.0502416864037514	0.0039902632124722	0.0509086959064007		
Neurônio 8	0.0737460479140282	0.126221835613251	-0.707732141017914	-0.0406540930271149		
Neurônio 9	-0.0412246957421303	-0.0554980635643005	0.0268764700740576	-0.083659790456295		
Neurônio 10	0.080516666173935	0.0652971863746643	-0.0905775502324105	0.01921696215868		
Neurônio 11	0.0954463854432106	0.115269653499126	-0.581245481967926	-0.0498432479798794		
Neurônio 12	0.10201271623373	0.140049338340759	-0.726436853408814	-0.0364863239228725		
Neurônio 13	-0.0247075073421001	0.0705160200595856	-0.013190888799727	-0.0891988649964333		
Neurônio 14	-0.0111053185537457	0.152227863669395	-0.180026039481163	-0.0173295754939318		
Neurônio 15	-0.0600112937390804	0.0134167559444904	0.113173000514507	-0.0726444405066967		
Neurônio 16	0.123036749660969	0.0888700783252716	-0.135446652770042	0.0585793182253838		

Tabela 35: Pesos do Segundo Layer (cont.)

Pesos do Output Layer					
	Segundo Layer - Neurônio 1	Segundo Layer - Neurônio 2	Segundo Layer - Neurônio 3	Segundo Layer - Neurônio 4	
Output Layer	0.582780957221985	0.074634224176407	0.664323925971985	-0.367809534072876	
Pesos do Output Layer (cont.)					
	Segundo Layer - Neurônio 5	Segundo Layer - Neurônio 6	Segundo Layer - Neurônio 7	Segundo Layer - Neurônio 8	
Output Layer	-0.556111872196198	-0.0588836121112108	0.379551768302917	0.628188371658325	
Pesos do Output Layer (cont.)					
	Segundo Layer - Neurônio 9	Segundo Layer - Neurônio 10	Segundo Layer - Neurônio 11	Segundo Layer - Neurônio 12	
Output Layer	-0.098691590130329	-0.923230469226837	0.71166318655014	0.458555728197098	
Pesos do Output Layer (cont.)					
	Segundo Layer - Neurônio 13	Segundo Layer - Neurônio 14	Segundo Layer - Neurônio 15	Segundo Layer - Neurônio 16	
Output Layer	-0.323340773582458	0.039837278425694	-0.456351727247238	0.300614148378372	

Tabela 36: Pesos do Output Layer

Bias do Primeiro Layer	
	Bias
Neurónio 1	0.0170130115002394
Neurónio 2	-0.0289147309958935
Neurónio 3	0.0107094757258892
Neurónio 4	-0.0812955051660538
Neurónio 5	0.0145125472918153
Neurónio 6	0.0023476246278733
Neurónio 7	0.0553195141255856
Neurónio 8	-0.00586182065308094
Neurónio 9	-0.0526842474937439
Neurónio 10	0.0553230755031109
Neurónio 11	0.0372035689651966
Neurónio 12	0.00894781481474638
Neurónio 13	-0.0181071367114782
Neurónio 14	-0.0428818427026272
Neurónio 15	-0.117091350257397
Neurónio 16	-0.014021847397089

Tabela 37: Bias do Primeiro Layer

Bias do Segundo Layer	
	Bias
Neurónio 1	0.0191870275884867
Neurónio 2	-0.0129654463380575
Neurónio 3	0.00339388684369624
Neurónio 4	-0.00922343973070383
Neurónio 5	-0.00794601626694202
Neurónio 6	-0.00593086052685976
Neurónio 7	0.00399562623351812
Neurónio 8	0.0190877467393875
Neurónio 9	-0.00585601897910237
Neurónio 10	-0.0611255429685116
Neurónio 11	-0.00861797295510769
Neurónio 12	0.0220632590353489
Neurónio 13	-0.00694218138232827
Neurónio 14	-0.0106437522917986
Neurónio 15	0.0254266243427992
Neurónio 16	0.0170805305242539

Tabela 38: Bias do Segundo Layer

Bias do Output Layer	
	Bias
Output	0.019923685118556

Tabela 39: Bias do Output Layer

Código Fonte

```
1 from keras.models import Sequential
2 from keras.layers import Dense, Dropout
3 import matplotlib.pyplot as plt
4 import numpy as np
5 import pandas as pd
6 import scipy.stats as stats
7 from sklearn.model_selection import train_test_split, StratifiedShuffleSplit,
  ↪ GridSearchCV
8 from sklearn import preprocessing
9 from sklearn import svm
10 from sklearn.preprocessing import MinMaxScaler, StandardScaler
11
12 # Reproducible data
13 np.random.seed(0)
14
15 # CONST
16 VARIABLES = ['CCC', 'DPO', 'DIO', 'DSO', 'OC']
17 COUNTRIES = ['ES', 'FR', 'IT', 'PT']
18
19 #####
20 #                               Data Wrangling                               #
21 #####
22
23 # Import data
24 dataset = pd.read_csv('./amadeus_export_4_revised.csv', sep=";")
25 print(dataset.head())
26
27 # Check data for one company
28 print(dataset.loc[dataset['Company name'] == "M H C S"].iloc[:, [1, 3, 6, 11, 21,
  ↪ 131, 171, 181, 141, 51, 151, 111]])
29
30 # Transpose company data from columns to rows
31 companies = []
32
33 # Cycle between all 10 columns (years) of data
34 for col in range(10):
35     # Select columns for each year
36     company = dataset.iloc[:, [1, # Company name
37                               3, # Country ISO code
38                               6, # Last year
39                               10 + col, # Debtors EUR Last avail. yr
```

```

40         20 + col, # Creditors EUR Last avail. yr
41         130 + col, # Sales EUR Last avail. yr
42         170 + col, # Material costs EUR Last avail. yr
43         # 160 + col, # Costs of goods sold EUR Last avail.
         ↪ yr
44         180 + col, # EBITDA EUR Last avail. yr
45         140 + col, # Operating revenue (Turnover) EUR Last
         ↪ avail. yr
46         50 + col, # Profit margin % Last avail. yr
47         150 + col, # Cash flow EUR Last avail. yr
48         110 + col # Long term debt EUR Last avail. yr
49     ]]
50
51     # Rename columns to concat later
52     company = company.rename(index=str, columns={
53         company.columns[0]: "Name",
54         company.columns[1]: "Country",
55         company.columns[2]: "Year",
56         company.columns[3]: "Debtors",
57         company.columns[4]: "Creditors",
58         company.columns[5]: "Sales",
59         company.columns[6]: "Material Cost",
60         company.columns[7]: "EBITDA",
61         company.columns[8]: "Operating Revenue",
62         company.columns[9]: "Profit Margin",
63         company.columns[10]: "CashFlow",
64         company.columns[11]: "Longterm Debt",
65     })
66
67     # Update year
68     company['Year'] = company['Year'] - col
69     companies.append(company)
70
71     # Concat all years
72     company_data = pd.concat(companies)
73     print(company_data.sort_values(by=['Year']).head())
74
75     # Show data for a single company
76     print(company_data.loc[company_data['Name'] == "M H C S"])
77
78     # Calculate DPO, DIO, DSO, OC and CCC
79     # DPO = Days Payment Outstanding == Prazo Médio de Pagamento
80     company_data['DPO'] = company_data['Creditors'] / company_data['Material Cost'] *
         ↪ 365

```

```

81
82 # DIO = Days Inventory Outstanding == Prazo Médio de Rotação de Inventários
83 company_data['DIO'] = (company_data['Sales'] - company_data['Material Cost']) /
84     ↪ company_data['Material Cost'] * 365
85
86 # DSO = Days Sales Outstanding == Prazo Médio de Recebimentos
87 company_data['DSO'] = company_data['Debtors'] / company_data['Sales'] * 365
88
89 # OC = Operational Cycle == Ciclo Operacional
90 company_data['OC'] = company_data['DSO'] + company_data['DIO']
91
92 # CCC = Cash Conversion Cycle == Ciclo de Conversão de Caixa
93 company_data['CCC'] = company_data['OC'] - company_data['DPO']
94
95 # Replace inf with N/A
96 company_data = company_data.replace([np.inf, -np.inf], np.nan)
97
98 # Drop all N/A
99 company_data = company_data.dropna()
100 print(company_data.sort_values(by=['CCC'], ascending=[0]).head())
101
102 #####
103 # Remove Outliers #
104 #####
105
106 # Filtered by quartil chart
107 d = company_data
108 filtered_data = []
109
110 for country in COUNTRIES:
111     f_df = d[d['Country'] == country]
112     for variable in VARIABLES:
113         f_df = f_df[f_df[variable] <= f_df[variable].quantile(0.75)]
114         f_df = f_df[f_df[variable] >= f_df[variable].quantile(0.25)]
115     f_df = f_df[f_df['EBITDA'] <= f_df['EBITDA'].quantile(0.75)]
116     f_df = f_df[f_df['EBITDA'] >= f_df['EBITDA'].quantile(0.25)]
117     f_df = f_df[f_df['CashFlow'] <= f_df['CashFlow'].quantile(0.75)]
118     f_df = f_df[f_df['CashFlow'] >= f_df['CashFlow'].quantile(0.25)]
119     filtered_data.append(f_df)
120
121 company_data = pd.concat(filtered_data)
122
123 # Company count - companies and ANN data
124 company_count = company_data.drop_duplicates('Name')

```

```

124 company_count_description = pd.pivot_table(company_count, values=['Name'],
    ↪ index=['Year'], columns=['Country'], aggfunc='count', margins=True)
125 print(company_count_description)
126
127 ann_dataset = pd.pivot_table(company_data, values=['Name'], index=['Year'],
    ↪ columns=['Country'], aggfunc='count', margins=True)
128 print(ann_dataset)
129
130 #####
131 #                               Pearson Correlation                               #
132 #####
133
134 data_c = {'ES': [], 'FR': [], 'IT': [], 'PT': [], 'GLOBAL': []}
135 data_s = {'ES': [], 'FR': [], 'IT': [], 'PT': [], 'GLOBAL': []}
136
137 for country in COUNTRIES:
138     country_data = company_data[company_data['Country'] == country]
139     print('-' * 100)
140     print('País %s' % country)
141     for variable in VARIABLES:
142         pearson_r = stats.pearsonr(country_data[variable],
    ↪ country_data['EBITDA'])
143         data_c[country].append(pearson_r[0])
144         data_s[country].append(pearson_r[1])
145
146         if pearson_r[1] <= 0.06:
147             print("Correlação (%s) %.2f - Significância %.2f%%" % (variable,
    ↪ pearson_r[0], (1 - pearson_r[1]) * 100))
148
149 print('-' * 100)
150 print('GLOBAL')
151 for variable in VARIABLES:
152     pearson_r = stats.pearsonr(company_data[variable], company_data['EBITDA'])
153     data_c['GLOBAL'].append(pearson_r[0])
154     data_s['GLOBAL'].append(pearson_r[1])
155
156     if pearson_r[1] <= 0.06:
157         print("Correlação (%s) %.2f - Significância %.2f%%" % (variable,
    ↪ pearson_r[0], (1 - pearson_r[1]) * 100))
158
159 # Rounding
160 correls_s = pd.DataFrame(data_s, index=VARIABLES).round(2)
161 correls_c = pd.DataFrame(data_c, index=VARIABLES).round(2)
162

```

```

163 print (correls_c)
164 print (correls_s)
165
166 # Basic statistics for each country
167 es_data = company_data[company_data['Country'] == 'ES'].describe().transpose()
168 fr_data = company_data[company_data['Country'] == 'FR'].describe().transpose()
169 it_data = company_data[company_data['Country'] == 'IT'].describe().transpose()
170 pt_data = company_data[company_data['Country'] == 'PT'].describe().transpose()
171
172 # Show data
173 print (es_data)
174 print (fr_data)
175 print (it_data)
176 print (pt_data)
177
178 def plot_quartile(v, ylim):
179     fig_name = './results/boxplot_' + v.lower() + '_final.png'
180
181     fig, ax = plt.subplots(figsize=(10, 10))
182     data = [
183         company_data[company_data['Country'] == 'ES'][v],
184         company_data[company_data['Country'] == 'FR'][v],
185         company_data[company_data['Country'] == 'IT'][v],
186         company_data[company_data['Country'] == 'PT'][v]
187     ]
188     ax.boxplot(data, False, 'o', True, 1.5)
189
190     ax.set_ylim(ylim)
191     plt.xticks([1, 2, 3, 4], ['ES', 'FR', 'IT', 'PT'])
192     plt.title('Dispersão do ' + v + ' das empresas de cada país')
193     plt.savefig(fig_name)
194     plt.show()
195
196 values_n = [
197     'CCC',
198     'OC',
199     'EBITDA',
200     'DPO',
201     'DSO',
202     'DIO'
203 ]
204
205 values_ylim = [
206     [-50, 500],

```

```

207     [150, 600],
208     [0, 1400000],
209     [0, 350],
210     [50, 250],
211     [50, 500]
212 ]
213
214 # Plot each chart with axes limits
215 for i in range(len(values_n)):
216     plot_quartile(values_n[i], values_ylim[i])
217
218 # Compare countries
219 country_comparison = company_data.groupby('Country').mean().transpose()
220 print(country_comparison)
221
222 # Average ['CCC', 'DPO', 'DIO', 'DSO'] by country
223 ccc = pd.pivot_table(company_data, values=['CCC'], index=['Year'],
224                       ↪ columns=['Country'])
225 dpo = pd.pivot_table(company_data, values=['DPO'], index=['Year'],
226                       ↪ columns=['Country'])
227 dio = pd.pivot_table(company_data, values=['DIO'], index=['Year'],
228                       ↪ columns=['Country'])
229 dso = pd.pivot_table(company_data, values=['DSO'], index=['Year'],
230                       ↪ columns=['Country'])
231 oc = pd.pivot_table(company_data, values=['OC'], index=['Year'],
232                     ↪ columns=['Country'])
233 ebitda = pd.pivot_table(company_data, values=['EBITDA'], index=['Year'],
234                          ↪ columns=['Country'])
235 variables_data = [ccc, dpo, dio, dso, dso, oc, ebitda]
236
237 plt.figure(figsize=(15, 15))
238
239 order = 1
240 for variable in VARIABLES:
241
242     plt.subplot(3, 2, order)
243     plt.plot(variables_data[order-1])
244     plt.legend(variables_data[order-1])
245     plt.title(variable)
246     order += 1
247
248 plt.subplot(3, 2, 6)
249 plt.plot(ebitda)
250 plt.legend(ebitda)

```

```

245 plt.title('EBITDA')
246
247 plt.savefig('./results/global_statistics_final.png')
248
249 plt.show()
250
251 #####
252 #                               Save Excel File                               #
253 #####
254
255 excel_writer = pd.ExcelWriter('./csv/CompleteData.xlsx')
256
257 es_data.to_excel(excel_writer, 'es_data')
258 fr_data.to_excel(excel_writer, 'fr_data')
259 it_data.to_excel(excel_writer, 'it_data')
260 pt_data.to_excel(excel_writer, 'pt_data')
261 company_data.to_excel(excel_writer, 'company_data')
262 ann_dataset.to_excel(excel_writer, 'ann_dataset')
263 country_comparison.to_excel(excel_writer, 'country_comparison')
264 company_count_description.to_excel(excel_writer, 'company_count')
265 ccc.to_excel(excel_writer, 'ccc')
266 dpo.to_excel(excel_writer, 'dpo')
267 dio.to_excel(excel_writer, 'dio')
268 dso.to_excel(excel_writer, 'dso')
269 oc.to_excel(excel_writer, 'oc')
270 ebitda.to_excel(excel_writer, 'ebitda')
271 correls_c.to_excel(excel_writer, 'correlation')
272 correls_s.to_excel(excel_writer, 'significance')
273
274 excel_writer.save()
275
276 # Search for a company
277 print(company_data.loc[company_data['Name'] == "VINICOLA SANT'ANNA SRL"])
278 print(company_data.loc[company_data['Name'] == "TENUTE SALENTINE S.R.L."])
279
280 # Save to csv
281 company_data.to_csv('./csv/training_data.csv')
282 print(company_data.head())
283
284 #####
285 #                               ANN                               #
286 #####
287
288 def draw_neural_net(ax, left, right, bottom, top, layer_sizes):

```

```

289     '''
290     Draw a neural network cartoon using matplotlib.
291
292     :usage:
293         >>> fig = plt.figure(figsize=(12, 12))
294         >>> draw_neural_net(fig.gca(), .1, .9, .1, .9, [4, 7, 2])
295
296     :parameters:
297         - ax : matplotlib.axes.AxesSubplot
298             The axes on which to plot the cartoon (get e.g. by plt.gca())
299         - left : float
300             The center of the leftmost node(s) will be placed here
301         - right : float
302             The center of the rightmost node(s) will be placed here
303         - bottom : float
304             The center of the bottommost node(s) will be placed here
305         - top : float
306             The center of the topmost node(s) will be placed here
307         - layer_sizes : list of int
308             List of layer sizes, including input and output dimensionality
309     '''
310     v_spacing = (top - bottom)/float(max(layer_sizes))
311     h_spacing = (right - left)/float(len(layer_sizes) - 1)
312     # Nodes
313     for n, layer_size in enumerate(layer_sizes):
314         layer_top = v_spacing*(layer_size - 1)/2. + (top + bottom)/2.
315         for m in range(layer_size):
316             circle = plt.Circle((n*h_spacing + left, layer_top - m*v_spacing),
317                               ↪ v_spacing/4.,
318                               color='w', ec='k', zorder=4)
319             ax.add_artist(circle)
320     # Edges
321     for n, (layer_size_a, layer_size_b) in enumerate(zip(layer_sizes[:-1],
322                                                         ↪ layer_sizes[1:])):
323         layer_top_a = v_spacing*(layer_size_a - 1)/2. + (top + bottom)/2.
324         layer_top_b = v_spacing*(layer_size_b - 1)/2. + (top + bottom)/2.
325         for m in range(layer_size_a):
326             for o in range(layer_size_b):
327                 line = plt.Line2D([n*h_spacing + left, (n + 1)*h_spacing + left],
328                                   ↪ [layer_top_a - m*v_spacing, layer_top_b -
329                                   ↪ o*v_spacing], c='k')
330                 ax.add_artist(line)

```

```

330
331 fig = plt.figure(figsize=(12, 12))
332 ax = fig.gca()
333 ax.axis('off')
334 draw_neural_net(ax, .1, .9, .1, .9, [5, 16, 16, 1])
335 fig.savefig('./results/nn_final.png')
336
337 # importing the dataset
338 dataset = pd.read_csv('./csv/training_data.csv')
339 dataset['CCC'] = [int(x) for x in dataset['CCC']]
340 dataset['OC'] = [int(x) for x in dataset['OC']]
341 dataset['DSO'] = [int(x) for x in dataset['DSO']]
342 dataset['DIO'] = [int(x) for x in dataset['DIO']]
343 dataset['DPO'] = [int(x) for x in dataset['DPO']]
344 dataset['EBITDA to Sales Ratio'] = dataset['EBITDA'] / dataset['Sales']
345 dataset['Sales EBITDA Ratio'] = dataset['Sales'] / dataset['EBITDA']
346 dataset.dropna()
347
348 print(dataset.sort_values(by=['CCC'], ascending=[0]).head())
349
350 plt.figure(1, figsize=(10, 5))
351
352 plt.subplot(1, 1, 1)
353 plt.scatter(dataset['CCC'], dataset['EBITDA'], dataset['Profit Margin'])#,
    ↪ dataset['EBITDA to Sales Ratio'])
354 plt.title('Dispersão do CCC pelo EBITDA')
355 plt.savefig('./results/scatter_result_final.png')
356 plt.show()
357
358 # it can also be ...iloc[:, [2, 3, 4, 5....]].values
359 X = dataset.iloc[:, 12:17].values
360 print("X 1:", X[0])
361
362 y = dataset.iloc[:, 7].values
363 print("Y 1:", y[0])
364
365 # split the dataset into training and test sets
366 X_train, X_tv, y_train, y_tv = train_test_split(X, y, test_size=0.20,
    ↪ random_state=0)
367 X_test, X_val, y_test, y_val = train_test_split(X_tv, y_tv, test_size=0.50,
    ↪ random_state=0)
368
369 # scale features
370 sc = MinMaxScaler()

```

```

371 X_train = sc.fit_transform(X_train)
372 X_val = sc.transform(X_test)
373 X_test = sc.transform(X_test)
374
375 # Must have a linear dense activation, teste 1, 7
376 y_scaler = MinMaxScaler()
377 y_train = y_scaler.fit_transform(y_train.reshape(-1, 1))
378 y_val = y_scaler.transform(y_test.reshape(-1, 1))
379 y_test = y_scaler.transform(y_test.reshape(-1, 1))
380
381 print(X_train.shape, y_train.shape)
382
383 # initialising
384 model = Sequential()
385
386 model.add(Dense(16, kernel_initializer='normal', activation='relu',
↪ input_shape=(5, )))
387
388 model.add(Dense(16, kernel_initializer='normal', activation='relu'))
389
390 # output layer
391 model.add(Dense(1))
392
393 # compiling mean_squared_logarithmic_error
394 model.compile(optimizer='adam', loss='mse', metrics=['mse', 'mae',
↪ 'mean_squared_logarithmic_error', 'mean_absolute_percentage_error'])
395
396 # fitting the ANN
397 # validation_data=(X_val,y_val), 16
398 history = model.fit(X_train, y_train, batch_size=32, epochs=200, verbose=0)
399
400 plt.figure(figsize=(20, 5))
401 plt.subplot(131)
402 plt.plot(history.history['mean_squared_error'])
403 plt.title('LOSS: Mean Squared Error')
404 plt.subplot(132)
405 plt.plot(history.history['mean_absolute_error'])
406 plt.title('LOSS: Mean Absolute Error')
407 plt.subplot(133)
408 plt.plot(history.history['mean_squared_logarithmic_error'])
409 plt.title('LOSS: Mean Squared Logarithmic Error')
410 plt.savefig('learning_graph_result_8.png')
411 plt.show()
412

```

```

413 # predict test dataset
414 y_pred = model.predict(X_test)
415
416 # Show results
417 fig, ax1 = plt.subplots(figsize=(10, 5))
418
419 color = 'tab:red'
420 ax1.set_xlabel('Empresa')
421 ax1.set_ylabel('EBITDA previsto', color=color)
422 ax1.plot(y_pred[-10:], color=color)
423 ax1.tick_params(axis='y', labelcolor=color)
424
425 ax2 = ax1.twinx() # instantiate a second axes that shares the same x-axis
426
427 color = 'tab:blue'
428 ax2.set_ylabel('EBITDA esperado', color=color) # we already handled the x-label
    ↪ with ax1
429 ax2.plot(y_test[-10:], color=color)
430 ax2.tick_params(axis='y', labelcolor=color)
431
432 plt.title('Variação prevista vs Variação esperada')
433
434 fig.tight_layout() # otherwise the right y-label is slightly clipped
435 plt.savefig('./results/prediction_real_comparison_result_final.png')
436 plt.show()
437
438 # predict test dataset
439 y_pred = model.predict(X_test)
440
441 y_pred_table = np.append([], y_pred[-10:])
442 y_test_table = np.append([], y_test[-10:])
443
444 plt.figure(figsize=(20, 5))
445 plt.subplot(111)
446 plt.bar(np.arange(10) - 0.11, y_pred_table, width=0.2)
447 plt.bar(np.arange(10) + 0.11, y_test_table, width=0.2)
448 plt.legend(['Previsão do EBITDA', 'Valor real esperado'])
449 plt.title('Comparação dos resultados previstos com os resultados esperados')
450 plt.savefig('./results/prediction_real_comparison_result_bar_final.png')
451 plt.show()
452
453 # Weights table column and rows names
454 i_col = ['Weight %s' % x for x in range(1, 6)]
455 x_col = ['Input Layer - Neuron %s' % x for x in range(1, 17)]

```

```

456 y_col = ['Inner Layer - Neuron %s' % x for x in range(1, 17)]
457 p_col = ['Output Layer - Neuron %s' % x for x in range(1, 17)]
458
459 # Weights tables
460 first_layer = pd.DataFrame(model.layers[0].get_weights()[0], columns=x_col,
    ↪ index=i_col).transpose()
461 second_layer = pd.DataFrame(model.layers[1].get_weights()[0], columns=y_col,
    ↪ index=x_col).transpose()
462 output_layer = pd.DataFrame(model.layers[2].get_weights()[0], columns=['Output
    ↪ Layer'], index=p_col).transpose()
463
464 # Bias tables
465 first_layer_bias = pd.DataFrame(model.layers[0].get_weights()[1],
    ↪ columns=['Bias'], index=x_col)
466 second_layer_bias = pd.DataFrame(model.layers[1].get_weights()[1],
    ↪ columns=['Bias'], index=y_col)
467 output_layer_bias = pd.DataFrame(model.layers[2].get_weights()[1],
    ↪ columns=['Bias'], index=['p'])
468
469 # Save weights to excel file
470 excel_writer = pd.ExcelWriter('./csv/Weights.xlsx')
471 first_layer.to_excel(excel_writer, 'first_layer')
472 second_layer.to_excel(excel_writer, 'second_layer')
473 output_layer.to_excel(excel_writer, 'output_layer')
474 first_layer_bias.to_excel(excel_writer, 'first_layer_bias')
475 second_layer_bias.to_excel(excel_writer, 'second_layer_bias')
476 output_layer_bias.to_excel(excel_writer, 'output_layer_bias')
477 excel_writer.save()
478
479 # First layer weights
480 print(first_layer)
481
482 # Second layer weights
483 print(second_layer)
484
485 # Output layer weights
486 print(output_layer)
487
488 # First layer bias
489 print(first_layer_bias)
490
491 # Second layer bias
492 print(second_layer_bias)
493

```

```

494 # Output layer bias
495 print(output_layer_bias)
496
497 #####
498 #                               SVM                               #
499 #####
500
501 clf = svm.SVR() # C=10, gamma=10
502 clf.fit(X_train, y_train)
503 print(clf.score(X_train, y_train))
504 print(clf.score(X_test, y_test))
505
506 # Predict test dataset
507 y_svm_pred = clf.predict(X_test)
508
509 y_svm_pred_table = np.append([], y_pred[-10:])
510 y_svm_test_table = np.append([], y_test[-10:])
511
512 plt.figure(figsize=(20, 5))
513 plt.subplot(111)
514 plt.bar(np.arange(10) - 0.11, y_svm_pred_table, width=0.2)
515 plt.bar(np.arange(10) + 0.11, y_svm_test_table, width=0.2)
516 plt.legend(['Previsão do EBITDA', 'Valor real esperado'])
517 plt.title('Comparação dos resultados previstos com os resultados esperados')
518 plt.savefig('./results/prediction_real_comparison_result_bar_svm_final.png')
519 plt.show()

```

Anexos

Demonstração de Resultados		
	Períodos	
	N	N-1
Vendas e Serviços Prestados	+	+
Subsídios à Exploração	+	+
Ganhos/perdas imputados de subsidiários, associadas e empreendimentos conjuntos	+ / -	+ / -
Variação nos inventários da produção	+ / -	+ / -
Trabalhos para a própria entidade	+	+
Custo das Mercadorias Vendidas e das Matérias Consumidas (CMVMC)	-	-
Fornecimentos e Serviços Externos	-	-
Gastos com o pessoal	-	-
Imparidade de inventários (perdas/reversões)	- / +	- / +
Imparidade de dívidas a receber (persas/reversões)	- / +	- / +
Provisões (aumentos/reduções)	- / +	- / +
Imparidade de investimentos não depreciáveis/amortizáveis (perdas/reversões)	- / +	- / +
Aumentos/reduções de justo valor	+ / -	+ / -
Outros rendimentos	+	+
Outros gastos	-	-
Resultado Operacional Bruto (EBITDA)	=	=
Gastos/reversões de depreciação e de amortização	- / +	- / +
Imparidade de investimentos depreciáveis/amortizáveis (perdas/reversões)	- / +	- / +
Resultado Operacional Líquido (EBIT)	=	=
Juros e rendimentos similares obtidos	+	+
Juros e gastos similares suportados	-	-
Resultado Antes de Impostos (RAI)	=	=
Imposto sobre o rendimento do período	- / +	- / +
Resultado Líquido do Período (RLP)	=	=

Tabela 40: Demonstração de Resultados - EBIT e EBITDA - Fonte: Diário da República, 1.^a série - N.º 143 - 24 de julho de 2015