

FACULDADE DE ENGENHARIA DA UNIVERSIDADE DO PORTO



FEUP

Integração de um módulo comercial no ERP jDx

João Luís Carvalho Pereira

VERSÃO DEFINITIVA

Relatório de Projecto
Mestrado Integrado em Engenharia Informática e Computação

Orientador: Ana Paula Rocha (Professor Auxiliar)

Julho de 2009

Integração de um módulo comercial no ERP jDx

João Luís Carvalho Pereira

Relatório de Projecto

Mestrado Integrado em Engenharia Informática e Computação

Aprovado em provas públicas pelo Júri:

Presidente: Maria Teresa Galvão (Professor Auxiliar)

Arguente: Orlando Manuel Oliveira Belo (Professor Associado)

Vogal: Orlando Manuel Oliveira Belo (Professor Associado)

31 de Julho de 2009

Resumo

A crescente competitividade do mercado e conseqüente exigência dos sistemas de informação presentes nas empresas, obrigou a uma alteração significativa no software empresarial, tendo-se verificado que desde meados da década de 80, aproximadamente até meados da década de 90, grandes empresas industriais optaram por ter os seus sistemas de computadores orientada em dois. O sistema industrial de um lado e os Administrativo / Financeiro do outro. Esta maneira de “ver” as coisas, tinha motivos óbvios a não dissecar, à partida era ineficiente porque implicava um nível de redundância de dados e "isolava" a informação que obviamente não devia ser separada. Desde então, a situação mudou e os empresários começaram a procurar soluções integradas. Só a partir deste momento podemos começar a conversar sobre ERPs (“*Enterprise Resource Planning*”), no mercado das pequenas e médias empresas industriais.

O principal objectivo deste projecto foi o de substituir o módulo comercial do ERP da Dinâmica, com as últimas tecnologias presentes no mercado (Java / *PostgreSQL*), de forma a dar um grande salto qualitativo no sistema, quer em termos tecnológicos, quer em termos de usabilidade.

Naturalmente, estas motivações e objectivos obrigaram a uma profunda revolução nos hábitos de desenvolvimento de código e utilização das tecnologias ao dispor. Não nos podemos esquecer que o actual ERP da Dinâmica está no mercado, desde o início da década.

Sem dúvida que o módulo comercial do ERP, está bem diferente do seu antecessor, para melhor, a todos os níveis, nas tecnologias desenvolvidas, no aspecto gráfico de todo o software e na facilidade e intuitividade de utilização do mesmo.

A utilização do método de redes neuronais “*Back-Propagation*” com o objectivo de prever volume de vendas, baseado em parâmetros de entrada bem definidos e no histórico de vendas na aprendizagem da rede, veio trazer valor acrescentado ao ERP e ajudar a distingui-lo da concorrência, será sem dúvida um excelente argumento de venda.

Abstract

The increasing competitiveness of the market and the consequent requirement of information systems in the companies, forcing a significant change in the software business since mid-80s, until approximately the mid-90s, large industrial companies have chosen to have his computer systems targeted in two. The industrial system on one hand and the Administrative / Finance on the other. This way of "see" things, had obvious reasons not to dissect, in the beginning was inefficient because it implied a level of redundancy of data and "isolate" the information that obviously should not be separated. Since then, the situation changed and the business began to look for integrated solutions. Only from this moment we can start talking about ERPs (Enterprise Resource Planning) in the market for small and medium industrial enterprises.

The main objective of this project was to replace the module of the commercial Dinâmica ERP, with the latest technologies in the market (Java / Postgresql) in order to make a great qualitative leap in the system, both in technological terms and in usability.

Of course, these motivations and goals, forced a profound revolution in the habits of developing code and in the use of the available technology. We must not forget that the current Dinâmica ERP is in the market since the beginning of the decade.

Undoubtedly, the commercial module of this ERP, is quite different from its predecessor, for the better, at all levels, the technologies used to develop and in the appearance of all the software and the easy and intuitive that it is to use it.

The method of neural networks "Back-Propagation" to predict sales volume, based on well-defined input parameters and the history of sales in the learning network, has added value to the ERP and help distinguish it, this will certainly be an excellent reference in a commercial point of view.

Agradecimentos

Ao meu irmão, companheiro de grande parte do meu trajecto profissional, bem como, como não poderia deixar de ser, de mais este degrau no nosso percurso académico. A constante troca de opiniões, debate construtivo das estratégias a seguir e tantos diálogos enriquecedores contribuíram de forma clara para este trabalho.

Ao Carlos Ferreira, que nos ajudou a partir “tanta pedra” nesta nossa aventura pelas novas tecnologias. São também já mais de vinte anos de trabalho, muitas vezes em comum.

À Professora, colega e amiga Ana Paula Rocha, pelos conselhos, pelo rigor científico, pela paciência que sempre demonstrou no apoio a este aluno que resolveu regressar à vida académica, dezoito anos depois de terminar a licenciatura.

À família, em especial à minha mãe, por todo o suporte em mais esta caminhada.

A todos os amigos, em especial à Rosa, que contribuíram de forma marcante para a execução deste trabalho.

O Autor: João Luís Carvalho Pereira

Índice

1	Introdução.....	1
1.1	Contexto/Enquadramento.....	1
1.2	Projecto	2
1.3	Motivação e Objectivos.....	4
1.4	Estrutura da Dissertação.....	4
2	Revisão Bibliográfica	5
2.1	Introdução	5
2.2	Novas necessidades do mercado	6
2.3	Tecnologias da Informação nas Empresas.....	7
2.4	ERP e SCM	8
2.4.1	Planeamento de Operações e Vendas	11
2.4.2	Casos de estudo de ERPs existentes.....	13
2.5	Data Mining	15
2.5.1	KDD.....	21
2.5.2	Regras de Associação.....	24
2.5.3	Redes neuronais	26
2.5.3.1	Redes Neuronais – Exemplos de Aplicação.....	31
2.6	Conclusões	34
3	Especificação do Módulo Comercial ERP jDx.....	35
3.1	Descrição do Problema	35
3.2	Módulo Comercial	35
3.3	Previsão de Vendas usando Redes Neuronais	36
3.4	Resumo e Conclusões	44
4	Implementação.....	45
4.1	A implementação do Módulo Comercial	47
4.1.1	Arquitectura lógica.....	48
4.1.2	Arquitectura física.....	50
4.1.2.1	Modelo	50
4.1.2.2	Arquitectura.....	51
4.1.2.4	Servidor de dados.....	51
4.1.3	Principais decisões de projecto do jDx	51

4.1.4	As tecnologias	52
4.1.4.1	Java	52
4.1.4.2	JBuilder	52
4.1.4.3	PostgreSQL	53
4.1.4.4	Jasper Report.....	53
4.1.4.5	iReport.....	53
4.2	A implementação do Quadro de Bordo	53
4.3	Previsão de Vendas.....	54
4.4	Conclusões	76
5	Conclusões e Trabalho Futuro	77
5.1	Satisfação dos Objectivos	77
5.2	Trabalho Futuro.....	78
REFERÊNCIAS	79

Lista de Figuras

Figura 1: Exemplo de um ERP (figura retirada de [Laudon, Laudon - 2006])	1
Figura 2: Mapa <i>Gant</i> do projecto “Integração de um Módulo Comercial no ERP jDx	3
Figura.3: Diagrama SOP	12
Figura 4: “ <i>Data Mining</i> ” e descoberta de conhecimento numa empresa	18
Figura 5: Arquitectura híbrida IDE	20
Figura 6: Exemplo de uma rede neuronal	20
Figura 7: O Processo KDD	22
Figura 8: Exemplo de uma Rede Neuronal	24
Figura 9: Exemplo de uma Árvore de decisão	25
Figura 10: Rede “feed-forward”	27
Figura 11: Processo “Back Propagation”	30
Figura 12: “ <i>Print Screen</i> ” da execução da classe “BrowserQuadroBordo” do projecto.....	36
Figura 13: “ <i>Print Screen</i> ” da execução da classe “BrowserQuadroBordo” do projecto (Vendas Mensais).....	37
Figura 14: Arquitectura de uma rede neuronal “ <i>Back Propagation</i> ”	38
Figura 15: Parâmetro “nº de funcionários” de entrada da rede neuronal	39
Figura 16: Parâmetro “nº de máquinas” de entrada da rede neuronal.....	39
Figura 17: Parâmetro valor de vendas no mesmo mês do ano anterior.....	40
Figura 18: Parâmetro “Evolução Mensal de Stock” de entrada da rede neuronal.....	41
Figura 19: Parâmetro “Evolução do P.I.B.” de entrada da rede neuronal (Fonte I.N.E.).....	42
Figura 20: Parâmetro “Evolução da Taxa de Desemprego” de entrada da rede neuronal (Fonte I.N.E.).....	43
Figura 21: Parâmetro “Evolução de Preços no Consumidor” de entrada da rede neuronal (Fonte I.N.E.).....	44
Figura 22 Relacionamento entre as tabelas de documentos comerciais do módulo comercial do projecto jDx.....	45
Figura 23: Arquitectura lógica do módulo comercial do jDx	48
Figura 24: Perspectiva geral do jDx.....	49
Figura 25: Algumas funcionalidades do módulo comercial jDx.....	50
Figura 26: Modelo de Arquitectura física do jDx	51
Figura 27: Arquitectura do jDx	51
Figura 28: A chamada da classe “BrowserQuadroBordo”	54
Figura 29: Menor erro médio absoluto em Análise 1 (parâmetros NF/PIB/PIC/TD)	57
Figura 30: Maior erro médio absoluto em Análise 1 (parâmetros NF/PIB/PIC/TD)	57
Figura 31: Menor erro médio absoluto em Análise 1 (parâmetros NF/NM/V/IPC)	59
Figura 32: Maior erro médio absoluto em Análise 1 (parâmetros NF/NM/V/IPC)	59
Figura 33: Menor erro médio absoluto em Análise 1 (parâmetros NF/NM/V/PIB)	61
Figura 34: Maior erro médio absoluto em Análise 1 (parâmetros NF/NM/V/PIB)	61
Figura 35: Menor erro médio absoluto em Análise 1 (parâmetros NF/NM/V/S)	63
Figura 36: Maior erro médio absoluto em Análise 1 (parâmetros NF/NM/V/S)	63
Figura 37: Menor erro médio absoluto em Análise 1 (parâmetros NF/NM/V/TD)	65
Figura 38: Maior erro médio absoluto em Análise 1 (parâmetros NF/NM/V/TD).....	65
Figura 39: Menor erro médio absoluto em Análise 2 (parâmetros NF/PIB/IPC/TD).....	67

Figura 40: Maior erro médio absoluto em Análise 2 (parâmetros NF/PIB/IPC/TD).....	67
Figura 41: Menor erro médio absoluto em Análise 2 (parâmetros NF/NM/V/IPC).....	69
Figura 42: Maior erro médio absoluto em Análise 2 (parâmetros NF/NM/V/IPC).....	69
Figura 43: Menor erro médio absoluto em Análise 2 (parâmetros NF/NM/V/PIB).....	71
Figura 44: Maior erro médio absoluto em Análise 2 (parâmetros NF/NM/V/PIB).....	71
Figura 45: Menor erro médio absoluto em Análise 2 (parâmetros NF/NM/V/S).....	73
Figura 46: Maior erro médio absoluto em Análise 2 (parâmetros NF/NM/V/S).....	73
Figura 47: Menor erro médio absoluto em Análise 2 (parâmetros NF/NM/V/TD).....	75
Figura 48: Maior erro médio absoluto em Análise 2 (parâmetros NF/NM/V/TD).....	75

Lista de Tabelas

Tabela 1: Resumo dos resultados obtidos em Análise 1 (parâmetros: NF/PIB/IPC/TD).....	56
Tabela 2: Resumo dos resultados obtidos em Análise 1 (parâmetros NF/NM/V/IPC).....	58
Tabela 3: Resumo dos resultados obtidos em Análise 1 (parâmetros NF/NM/V/PIB).....	60
Tabela 4: Resumo dos resultados obtidos em Análise 1 (parâmetros NF/NM/V/S).....	62
Tabela 5: Resumo dos resultados obtidos em Análise 1 (parâmetros NF/NM/V/TD).....	64
Tabela 6: Resumo dos resultados obtidos em Análise 2 (parâmetros NF/PIB/IPC/TD).....	66
Tabela 7: Resumo dos resultados obtidos em Análise 2 (parâmetros NF/NM/V/IPC).....	68
Tabela 8: Resumo dos resultados obtidos em Análise 2 (parâmetros NF/NM/V/PIB).....	70
Tabela 9: Resumo dos resultados obtidos em Análise 2 (parâmetros NF/NM/V/S).....	72
Tabela 10: Resumo dos resultados obtidos em Análise 2 (parâmetros NF/NM/V/TD).....	74

Abreviaturas e Símbolos

ABAL	<i>Advanced Business Application Language</i> da Prologue
BI	<i>Business Intelligence</i>
CCM	<i>Continuous Controls Monitoring</i>
CRM	<i>Customer Relationship Management</i>
Data Mining	É o processo de extrair padrões ocultos de dados
DBMS	<i>Database Management System</i>
Dialogue3	Sistema de Gestão de Base de Dados da Prologue
Dinâmica	Micro Empresa
Dinamix	ERP desenvolvido pela Dinâmica
EAI	<i>Enterprise Application Integration</i>
ERP	<i>Enterprise Resource Planning</i>
IT	<i>Information Technology</i>
iReport	Gerador de relatórios da <i>Jasper Reports</i>
JBuilder	IDE (<i>Integrated Development Environment</i>) da Borland
jDx	ERP que a Dinâmica está a desenvolver
mySAP	Importante ERP presente no mercado
Oracle	Companhia de Sistemas de Informação
PostgreSql	Motor de Base de dados
Prologue	Construtor Francês de software e hardware
KPI	Standard “Key Performance Indicators
SAP	Empresa de Sistemas de Informação
SCM	<i>Supply Chain Management</i>
SCOR	<i>Supply Chain Operations Reference</i>
SCM	<i>Sales and Operations Planning</i>

1 Introdução

1.1 Contexto/Enquadramento

No mercado global em que vivemos, as empresas estão cada vez mais ligadas, tanto internamente como externamente com outras empresas. Tal facto justifica-se pela necessidade de responder às exigências crescentes do mercado onde as empresas se vêem obrigadas a reagir instantaneamente e adaptar-se a qualquer alteração do mercado, seja por exemplo quando um cliente coloca uma nova encomenda, ou quando se regista um atraso na encomenda de um fornecedor. Para responder de forma eficiente a estes novos requisitos, os responsáveis das empresas querem conhecer o impacto de tais eventos em cada parte do negócio e como o negócio se está a desenvolver em qualquer instante de tempo. A empresa deverá possuir sistemas de integração para tornar isso possível.

Os ERP (“*Enterprise Resource Planning*”) são sistemas baseados na integração de diferentes módulos de software com uma base de dados central (ver Figura 1).

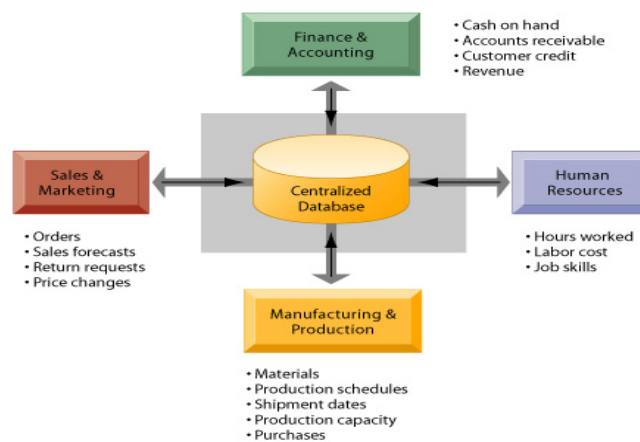


Figura 1: Exemplo de um ERP (figura retirada de [Laudon, Laudon - 2006])

Introdução

A base de dados armazena dados de e alimenta dados para numerosas aplicações que podem suportar todas as actividades internas da organização. Quando uma nova informação entra por um processo, essa informação torna-se imediatamente disponível para outros processos de negócio.

Se um vendedor colocar uma encomenda com uma data de entrega pedida pelo cliente, o sistema iria verificar o limite de crédito do cliente, agendar a transferência, identificar a melhor rota, e reservar o stock dos artigos necessários. Se o stock não for suficiente para satisfazer a encomenda, o sistema iria agendar o fabrico desses artigos, encomendando os materiais necessários aos fornecedores. Os dados comerciais, financeiros e de previsões de produção seriam imediatamente actualizados. Os utilizadores poderão entrar no sistema e descobrir o estado dessa encomenda, em qualquer minuto.

A gestão poderá obter informações, em qualquer momento, sobre a forma como a empresa está operando. O sistema pode também gerar dados a nível empresarial para a gestão e análises de custo e rentabilidade do produto.

Os sistemas nas empresas podem assim criar alicerces para uma relação mais orientada para o cliente. Ao integrar os processos empresariais discretos nas vendas, produção, finanças e logística, a organização pode de uma forma mais eficiente dar resposta às solicitações dos clientes para os produtos ou informação, previsão de novos produtos, bem como prever e entregar a encomenda conforme pedida. A produção ficará melhor informada sobre o que os clientes pediram, apenas produzindo o necessário, procurando exactamente a quantidade de componentes ou matérias-primas para preencher ordens reais, minimizando o tempo que os componentes ou produtos acabados estão em stock.

O trabalho relatado neste documento decorreu na empresa Dinâmica – Projectos Consultoria e Organização, Lda., micro empresa de prestação de serviços e desenvolvimento de software, e integra o módulo comercial, do novo ERP que a empresa está a desenvolver, jDx, utilizando tecnologia JAVA.

1.2 Projecto

O módulo comercial que está na base do trabalho descrito neste documento irá integrar o ERP da empresa em conjunto com outros módulos já desenvolvidos, em desenvolvimento (módulo financeiro e de logística) ou a desenvolver num futuro próximo.

As expectativas são de que, em Junho de 2009, o módulo comercial do ERP jDx esteja acabado e todos os outros módulos concluídos em 2010 (o módulo financeiro, deverá estar concluído antes de Junho de 2009 e o módulo de logística em Junho de 2009).

O trabalho irá assentar em tecnologias Java, que como sabemos estão em constante actualização, o que é muito importante para o futuro do produto.

Todas as principais classes e relatórios a desenvolver serão plenamente integrados no ERP, no final deste projecto.

Como resultados esperados pretende-se ter o módulo comercial bem desenvolvido, com as ferramentas mais recentes do mercado, simples e fácil de usar para os utilizadores e capaz de enfrentar a concorrência no mercado das pequenas e médias empresas da indústria metalomecânica (é o mercado alvo que se pretende atingir).

O problema da redundância da informação continua a ser um tema essencial em múltiplas situações

Introdução

As principais funcionalidades a incluir no módulo comercial são as seguintes:

- Configuração dos parâmetros comerciais da empresa
(onde se configuram os vários parâmetros da empresa, tais como números de vias em papel dos documentos comerciais, pasta onde se localizam os relatórios comerciais, etc.)
- Manutenção do ficheiro de Clientes
(manutenção de todos os campos acessíveis do ficheiro de clientes, tais como, nome, morada, website, etc.)
- Manutenção do ficheiro de Artigos
(manutenção de todos os campos acessíveis do ficheiro de artigos, tais como, designação, preço de venda, fotografia do produto, etc.)
- Manutenção de Documentos Comerciais
(criação, modificação, supressão, consulta dos vários tipos de documentos comerciais)
- Impressão de Documentos Comerciais
(listagem dos vários documentos comerciais)
- Relatórios Comerciais
(listagem dos vários relatórios comerciais, tais como, resumo de facturação, abc de vendas por referência, etc.)
- Quadro de Bordo da empresa
(quadro resumo das várias partes sensíveis à gestão da empresa, tais como, facturação mensal comparativa do ano em curso com ano anterior, e respectivos desvios, encomendas de clientes e fornecedores em aberto, por antiguidade, contas correntes de clientes e fornecedores, por antiguidade, etc.
- Previsão mensal de Vendas
(Utilizando o método de aprendizagem de redes neuronais “Back-Propagation”)

A calendarização do projecto é apresentada na figura 2:

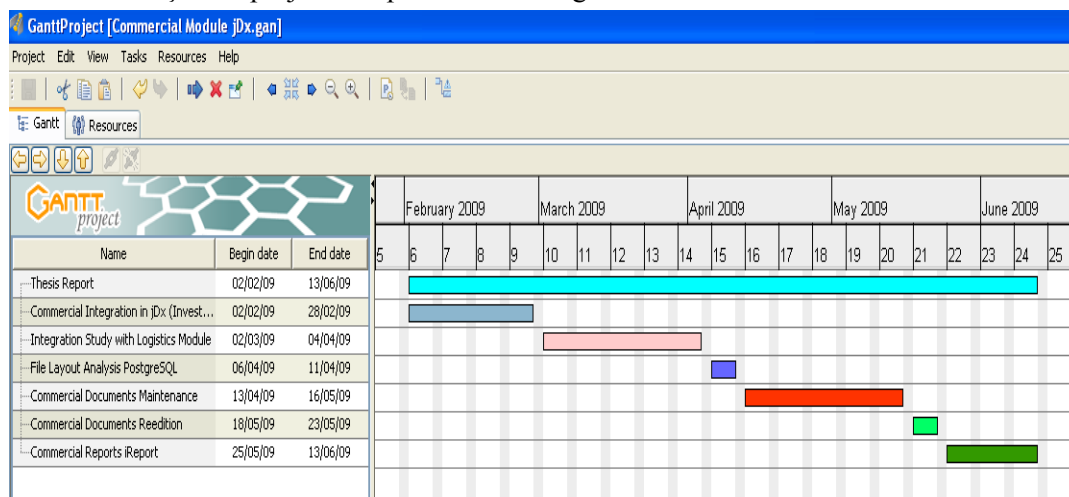


Figura 2: Mapa *Gantt* do projecto “Integração de um Módulo Comercial no ERP jDx

1.3 Motivação e Objectivos

O entendimento e a tentativa de dar resposta às necessidades actuais e futuras dos clientes da empresa Dinâmica são a principal motivação deste projecto.

A empresa Dinâmica, já com vários anos no mercado dos sistemas de informação para pequenas e médias empresas, possuía em 2005 um bom produto, fiável, que cumpria os potenciais requisitos dos clientes, mas não vendia (tratava-se de um produto orientado ao carácter). Após uma profunda reflexão, e depois de ouvir a opinião de vários especialistas na área de instituições de referência, optou-se pelo desenvolvimento num conjunto de ferramentas do mundo Java.

A escolha recaiu no triângulo *JBuilder (Borland) / PostgreSQL / Jasper Report-iReport*. A questão das ferramentas foi uma preocupação fulcral, porque em termos de análise, acreditamos estar bem no mercado que queremos atacar (mercado da metalomecânica, para empresas de pequena e média dimensão).

O principal objectivo deste projecto é desenvolver um novo módulo comercial, utilizando as últimas tecnologias presentes no mercado, para substituir o sistema que é actualmente comercializado pela Dinâmica, *Dinamix*. Este sistema está instalado no mercado desde 2000 e funciona no sistema operativo *Twin Server* (França), utilizando como linguagem de desenvolvimento o ABAL e como sistema de gestão de bases de dados o Dialogue3.

Devido à antiguidade do sistema que é actualmente comercializado pela Dinâmica, sentiuse a necessidade de o substituir por um novo, utilizando as últimas tecnologias presentes no mercado, e que em termos de funcionalidades superasse as já conhecidas pelos utilizadores habituados ao sistema antigo e que ultrapasse os constrangimentos comerciais que o sistema antigo sofre, pura e simplesmente já não é “comercializável” nos dias de hoje.

Pretende-se implementar um sistema que tenha todas as funcionalidades do sistema antigo, e que acrescente novas funcionalidades, nomeadamente as exigidas pelas novas realidades do mercado, e principalmente facilidade de utilização (o sistema antigo ainda foi todo desenvolvido em 80 colunas por 25 linhas...).

1.4 Estrutura da Dissertação

Para além da introdução, esta dissertação contém mais 5 capítulos. No capítulo 2, é descrito o estado da arte e são apresentados trabalhos relacionados. No capítulo 3 são descritas as especificações do projecto e a descrição do problema. No capítulo 4 é descrita a implementação do projecto. No capítulo 5 são efectuadas as conclusões do projecto e definido em traços gerais o trabalho futuro. Por fim no capítulo 6 são apresentadas as referências bibliográficas e as referências a artigos.

2 Revisão Bibliográfica

2.1 Introdução

Nesta secção é apresentado o conceito de Sistemas de Informação nas empresas, realçando o papel fundamental que estes desempenham no mercado actual. É descrito um sistema ERP (*Enterprise Resource Planning*), apresentando os principais módulos constituintes de um ERP, enumerando as suas principais características e vantagens.

Será ainda analisado SAP (“*Systeme, Anwendungen, Produkte*”, do alemão Sistemas, Aplicações e Produtos), como um dos principais ERP's presentes no mercado.

Como tecnologias utilizáveis são analisadas alternativas para tecnologias Java como linguagem de programação, *PostgreSql* como motor de bases de dados e relatórios *iReport* como gerador de relatórios. São analisadas e discutidas as vantagens e desvantagens de tais alternativas.

O *PostgreSql* é um dos resultados de uma ampla evolução que se iniciou com o projecto *Ingres*, desenvolvido na Universidade de Berkeley, Califórnia. O líder do projecto, Michael Stonebraker, um dos pioneiros das bases de dados relacionais, deixou a universidade em 1982 para comercializar o *Ingres*, porém retornou a ela logo em seguida. Após o seu regresso a Berkeley, em 1985, Stonebraker começou um projecto pós-*Ingres* com o objectivo de resolver problemas com o modelo de base de dados relacional. O principal problema era a incapacidade do modelo relacional compreender “tipos” (actualmente, chamados de objectos), ou seja, combinações de dados simples que formam uma única unidade.

O projecto resultante, chamado **Postgres**, era orientado a introduzir a menor quantidade possível de funcionalidades para completar o suporte a tipos. Estas funcionalidades incluíam a habilidade de definir tipos, mas também a habilidade de descrever relações - as quais até este momento eram amplamente utilizadas mas completamente mantidas pelo utilizador. No *Postgres*, a base de dados "compreendia" as relações e podia obter informações de tabelas relacionadas utilizando regras.

Iniciando em 1986, a equipa divulgou uma série de documentos descrevendo a base do sistema e em 1988 o projecto possuía um protótipo funcional. A versão 1 foi lançada para um grupo pequeno de utilizadores em Junho de 1989, seguida pela versão 2 com um sistema de regras reescrito em Junho de 1990. Para a versão 3, lançada em 1991, o sistema de regras foi reescrito novamente, mas também foram adicionados suporte para múltiplos gestores de armazenamento e um motor de consultas melhorado. Em 1993, *Postgres* havia crescido imenso em popularidade e possuía uma grande procura por suporte e por novas funcionalidades. Após o lançamento da versão 4, a qual era uma simples versão de limpeza, o projecto foi oficialmente abandonado pela Universidade de Berkeley.

Entretanto, devido ao facto do seu código fonte estar sobre uma licença BSD, o seu desenvolvimento foi continuado. Em 1994, dois estudantes de Berkeley, Andrew Yu e Jolly Chen, adicionaram um interpretador SQL para substituir a linguagem QUEL (desenvolvida para o Ingres) e o projecto foi renomeado para **Postgres95**. Com a divulgação de seu código pela Internet, Postgres95 iniciou uma nova caminhada como software *open source*.

Em Maio de 2000 foi lançada a versão 7.0. As versões 7.x trouxeram as seguintes funcionalidades: *Write-Ahead Log* (WAL), esquemas SQL, *outer joins*, suporte a IPv6, indexação por texto, suporte melhorado a SSL e informações estatísticas de bases de dados.

A versão 8.0 foi lançada em Janeiro de 2005 e entre outras novidades, foi a primeira a ter suporte nativo para Microsoft Windows (tradicionalmente, o PostgreSQL só era compatível de forma nativa em sistemas Unix e, em sistemas Windows - através da biblioteca Cygwin). Das muitas novidades da versão 8.x, pode-se destacar o suporte a *tablespaces*, *savepoints*, *point-in-time recovery*, *roles* e *Two-Phase-Commit* (2PC). Em Fevereiro de 2008 foi lançada a versão mais recente: 8.3.

2.2 *Novas necessidades do mercado*

Segundo Willard e Neil [WN04], as empresas de hoje são caracterizadas por uma elevada complexidade, resultado de um mercado extremamente competitivo e de uma concorrência muito intensa entre as empresas. Fruto desta ebulição, são necessários elevados níveis de qualidade nos produtos, mas também, preços mais baixos e maior qualidade no serviço pós-venda. Assim, o sucesso das empresas depende em grande parte da sua capacidade de negociar com os fornecedores e da sua capacidade de se adaptar às exigências dos clientes, quer ao nível do produto final, quer nos prazos de entrega dos mesmos.

Numa sociedade sem tempo, em que as pessoas têm acesso a um lote variado de serviços, torna-se difícil identificar as necessidades de cada cliente, recordar o seu passado, interações, ou inferir os seus desejos, com base em perfis.

Na sua análise, Anderson e Kerr [AK01], descreve o relacionamento com os clientes como um sistema integrado de gestão com foco no cliente, constituído por um conjunto de procedimentos e processos organizados e integrados num modelo de gestão de negócios.

Os tempos e os mercados estão a mudar na indústria e, especialmente, para a distribuição do negócio. Quais são os factores importantes para executar o negócio da rede de sucesso neste ambiente? Por um lado, há os impactos do mercado, as regras do mercado, a quota de mercado, os preços de energia e de serviços. Estes impactos determinam as receitas e a distribuição de

uma grande empresa. Por isso as empresas têm de reduzir os seus custos, se querem aumentar a rentabilidade dos seus negócios. Isso significa que têm de incidir sobre o investimento, para a manutenção dos seus activos, ao mesmo tempo, naturalmente, têm de garantir a qualidade dos seus serviços. Deverão ser também tomadas medidas de curto prazo para reduzir os custos de manutenção e operação.

É também tempo para pensar em novos conceitos para o investimento.

A base para esses novos conceitos é uma apertada relação entre o mundo dos custos e de informação contabilística e o mundo dos objectos técnicos. Esta ligação é uma característica fundamental para qualquer decisão de investimento ou de manutenção técnica.

A gestão de activos e de trabalho de gestão têm de ser um sistema integrado.

Por outro lado, é importante olhar para todo o ciclo de vida dos activos, do planeamento e concepção de operação e manutenção. Para garantir a saúde a longo prazo dos bens, as empresas têm de considerar esses ciclos de vida dos activos e dos custos associados ao risco como uma visão integrada. O risco baseado em optimização de recursos requer a utilização de sistemas de informação e ferramentas de análise poderosas.

Estas estratégias de manutenção (tais como a utilização de versões iguais instaladas em clientes, sendo os “upgrades” feitos via *Net* para todos, versus, uma manutenção dedicada cliente a cliente, mais onerosa, mas mais eficiente) exigem informações detalhadas sobre o estado real dos activos. Como a maioria dos activos pertencem a uma infra-estrutura distribuída, aplicações móveis suportam o apoio à recolha dos dados necessários. Comparando com o suporte em papel, a recolha de dados com dispositivos móveis não só é muito mais eficiente, como também origina menos erros, pois os dados são inseridos apenas uma vez. Além disso, ao fazer uso de rádio frequências, as identificações efectuadas pelos dispositivos móveis de recolha de dados, vão ser ainda mais eficientes, fiáveis e flexíveis. Para beneficiar destas ferramentas, aplicativos e fontes de dados têm de ser integrados, tanto quanto possível, para evitar a duplicação de dados. Isto significa uma integração das aplicações da empresa (EAI – *Enterprise Application Integration*), incluindo um portal quando necessário. Com base no conceito EAI, os processos de negócio podem perfeitamente incluir várias ferramentas e aplicativos, assegurando a coerência de dados entre os vários módulos dos sistemas de software. Ao mesmo tempo, o portal oferece aos usuários acesso a todas as aplicações, processos e dados que precisam de uma interface gráfica.

Assim, os utilizadores terão uma visão completa dos activos, incluindo informações comerciais, técnicas, de rede e informações geográficas. Os utilizadores podem então mais facilmente tomar decisões sobre as informações que estão disponíveis.

2.3 Tecnologias da Informação nas Empresas

Enquanto os efeitos da recessão ameaça os mercados e a riqueza do mundo, as empresas das economias emergentes estão em constante desenvolvimento e espalham o seu alcance à escala global. A maioria das empresas de mercados emergentes poderá proporcionar uma enorme oferta de trabalho, para apoiar o crescimento, mas a expansão internacional e a concorrência está a criar um conjunto de desafios completamente novos. Apesar do saudável crescimento da população em muitos países em desenvolvimento, é grande o número de jovens

que entram no mercado de trabalho, mas a concorrência de talentosos colaboradores por empregos continua a aumentar.

Grande parte dos executivos dos mercados emergentes esperam conseguir reter os seus melhores empregados, mas esperam também ter um crescimento mais difícil durante os próximos três anos. Não é de estranhar, neste contexto, que a gestão das empresas considere cada vez mais estes novos talentos como uma função integrante do negócio. Estas são algumas das principais conclusões de um programa de investigação, realizado pela “*Economist Intelligence Unit*” e patrocinado pela SAP².

Outras conclusões chave incluem o seguinte: o défice de competências está a aumentar. Não há falta de efectivos na maioria dos mercados emergentes, mas há uma profunda preocupação de que as suas habilitações poderão não conseguir atingir os requisitos das empresas. Grande parte dos executivos temem pelo crescente fosso entre as qualificações dos talentos saídos das universidades e o que as indústrias necessitam, e acreditam que isso se irá agravar. Muitos, especialmente a Rússia e a Índia, também temem a perda dos seus talentos para empregos mais atraentes no exterior.

Embora as TI (Tecnologias da Informação) e outras aptidões técnicas sejam importantes para o sucesso das empresas, os executivos dos mercados emergentes tem a possibilidade de gerir as mudanças e de pensar estrategicamente, com o auxílio das competências dos seus colaboradores, para tomar as decisões nas suas empresas ao longo dos próximos três anos. Mas eles também reconhecem que o talento e essas habilidades serão de longe as mais difíceis de encontrar.

As empresas vão ter dificuldades para atender as expectativas de salário dos colaboradores mais talentosos. A saída de funcionários é crescente em lugares como a Índia e a China.

A maioria dos gestores temem a incapacidade de satisfazer as expectativas salariais dos colaboradores e esse será um dos principais obstáculos no sucesso das suas empresas.

As empresas têm de cuidar da imagem dos projectos e serem claras sobre o que é que defendem. Nutrir lealdade à marca da empresa e aos seus valores passa a ser um factor cada vez mais importante das empresas na capacidade de atrair e reter funcionários. As empresas precisam ser mais criativas em descobrir onde e como fomentar talentos. Isto poderá significar a parceria com outras organizações de formação para criar consórcios, no sentido de garantir que as competências exigidas continuam a crescer, mas também poderá significar fornecer tecnologia para comunicações com as aldeias remotas, para tornar mais fácil à população local voltar a entrar no mercado de trabalho.

2.4 ERP e SCM

Os sistemas ERP (“*Enterprise Resource Planning*”) e SCM (“*Supply Chain Management*”) têm vindo a crescer em popularidade entre as diferentes indústrias como ferramentas essenciais na gestão de recursos e processos das empresas. Novas iniciativas no planeamento de recursos, e no comércio electrónico em geral, estão a conduzir a uma evolução

² SAP é uma empresa de desenvolvimento de software

da cadeia de abastecimento entre empresas no sentido de integrar aplicações empresariais estratégicas. Os sistemas ERP pretendem auxiliar as empresas na automatização e integração de funções corporativas transversais como o controlo na aquisição de materiais, distribuição, finanças e gestão de projectos. Através da partilha de informações, o SCM permite aos parceiros da cadeia de fornecimento trabalhar em estreita coordenação para facilitar a interacção entre o cliente e o fornecedor no sentido de minimizar custos. Esta secção examina estes dois importantes conceitos em termos da sua evolução, funções e desenvolvimento actual. Explora ainda os fundamentos para a sua integração através da análise dos problemas de ERP e apresenta algumas soluções de SCM.

A maioria das empresas considera os seus recursos humanos como o segredo para o sucesso. No mundo competitivo de hoje as empresas têm deslocado a sua atenção para a melhoria da produtividade, contando para isso com os seus colaboradores. Capacitar os funcionários, dando-lhes informação atempada aumenta a produtividade, e isso é exactamente o que faz um sistema integrado de informação, um ERP.

Aplicar práticas comerciais inteligentes, como a delegação da tomada de decisão, pode ajudar a controlar o desperdício de trabalho. Mas estas práticas só funcionam quando os gestores fornecem às pessoas a informação certa no momento certo para que eles possam gerir as suas responsabilidades. Isto é especialmente verdadeiro para os empregados que fazem o interface com o cliente. Muitas oportunidades para o aumento de produtividade dos empregados podem ser encontradas em áreas que não fazem parte da produção directa ou dos custos de produção. Isto pode parecer um contra-senso uma vez que a justificação para muitas implementações de sistemas ERP está reduzido a inventários de finanças. Por exemplo, se uma empresa tem uma produção eficiente e um bom controlo de matérias-primas, um gestor pode sentir que a oportunidade de aperfeiçoamento fora dessas áreas é limitada. Mas a verdade é que o uso de um sistema ERP pode ajudar a criar um ambiente que estimule indirectamente o aumento de produtividade.

Nos anos noventa, os tradicionais pacotes de software dos sistemas de informação da empresa eram construídos para o “*back office*”, não sendo por isso nessa altura importante desenvolver o software que faz o interface com o cliente, eram funções somente realizadas pelos funcionários das empresas.

Estes pacotes tradicionais exigiam uma ampla integração com as infra-estruturas tecnológicas e envolviam implementações onerosas e demoradas. Uma desvantagem ainda maior é o facto destes pacotes se tornarem cada vez mais difíceis de manter e actualizar, rendendo pouco valor comercial para os investimentos realizados. Actualmente, o esforço humano também tem evoluído e é muito mais descentralizado, globalmente disperso, colaborativo e efectuado muitas vezes *on-line*, exigindo assim sistemas de software flexíveis. A convergência das tendências tecnológicas, como o surgimento da Web 2.0, os produtos “*open source*”, os serviços *Web*, o desenvolvimento orientado a objectos, criou a necessidade de adopção de novas plataformas. Em resposta a estes requisitos, surge então uma nova geração de soluções ERP que oferecem inigualável agilidade e facilidade de uso com menor custo total de propriedade, e apresentam as seguintes características:

- “*On-demand*”: a entrega é efectuada com base na *Web*, apresenta uma arquitectura multi-plataforma, disponibilidade permanente (24 horas por dia) e segurança reforçada.

Revisão Bibliográfica

- Ágil e Global: rapidamente se adapta para atender às necessidades empresariais de mudança.
- Intuitiva: construída para a geração actual onde os empregados são pessoal qualificado; oferece relatórios e ferramentas analíticas que auxiliam as empresas na tomada de decisões de forma mais oportuna.
- Integração de serviços Web: oferece elevada capacidade de integração, minimizando a complexidade e o tempo de execução dos serviços.

O processo de selecção de uma boa solução empresarial, como é o caso de um ERP, é um grande investimento, que pode oferecer às empresas benefícios excepcionais ou riscos dramáticos. Quando executado correctamente pode agilizar processos, ajudar a “visão empresarial” e permitir às empresas melhor satisfazer a procura do mercado. Quando mal executado, os resultados podem variar de decepcionantes a devastadores.

A magnitude do risco que as empresas enfrentam ao adquirir uma solução de software empresarial está fortemente associada com a qualidade e a imparcialidade da informação utilizadas na sua avaliação e nos processos de selecção. A selecção de um sistema ou serviço que melhor corresponda às necessidades da empresa requer vários tipos de diligências, exige tempo e recursos que são retirados do núcleo de operações da organização. O custo de um sistema empresarial de uma empresa começa assim muito antes de o vendedor deste ser seleccionado.

Todo o processo de selecção e implementação de um sistema de “*BackOffice*” de uma pequena ou média empresa, por exemplo, pode demorar mais de seis meses. Destes, uma equipa despende entre três a quatro meses a realizar avaliações das necessidades internas e a avaliar outras soluções candidatas. Durante este período, a empresa é inundada com garantias de comercialização e com candidatos lutando para se diferenciar. A integração do software, as possíveis fusões e aquisições de diferentes candidatos podem comprometer ainda mais a qualidade da informação recolhida.

Porque geralmente as equipas seleccionadas não têm a capacidade de obter informações objectivas, analisados os dados disponíveis sobre as soluções dos candidatos. Esta situação pode ocorrer durante todo o processo, e originar mesmo a que se exceda o tempo e/ou orçamento do projecto. Na verdade, mais de metade de todas as implementações de software não satisfazem as expectativas, e pelo menos um terço têm falhas definitivas. As empresas frequentemente assumem que reduzindo os recursos e tempo gasto na recolha de informações estão a reduzir esses riscos. Mas ao fazê-lo, podem estar na realidade a comprometer o objectivo final.

O objectivo não é a empresa possuir um qualquer sistema de informação, mas sim melhorar o desempenho da organização.

Ao utilizar consultoras neste processo de selecção da melhor solução empresarial, utilizam-se menos recursos da organização, mas pode-se não atenuar os riscos de uma má escolha, porque muitas das consultoras também enfrentam os mesmos obstáculos como organizações, e podem empregar metodologias defeituosas para compensar.

Ao solicitar novos candidatos, devem-se reter os requisitos que são mais cruciais para a empresa e assegurar respostas honestas desses candidatos. Os analistas da indústria, por outro lado, devem incentivar a investigação em profundidade, sugerindo a selecção de equipas, adquirindo guias e revistas industriais, frequentando feiras, e entrando em contacto com empresas associadas e associações industriais para preencher a lacuna do conhecimento.

Estas abordagens podem resultar em mais tempo gasto, longe do núcleo de operações e não garantem qualidade e informação imparcial. O risco do mau acompanhamento de soluções está ainda presente. As organizações não devem sacrificar a qualidade da informação. Em vez disso, devem retirar as acções que não criam valor e racionalizar as que criam.

2.4.1 Planeamento de Operações e Vendas

O Planeamento de operações e vendas (cuja designação inglesa é “*Sales and Operations Planning*” - SOP) é das funções mais críticas que uma empresa deve realizar, tem efeitos em vários departamentos e tem o potencial de influenciar directamente os lucros da empresa. Um departamento que utiliza SOP com sucesso harmoniza as actividades dos diferentes departamentos. É um desafio encontrar uma ferramenta eficaz que consiga mesclar os dados de diferentes sistemas para criar uma imagem coerente da empresa.

SOP é um sistema utilizado pelos mais importantes departamentos de uma empresa: finanças, vendas, marketing e operações. Esta é a razão pela qual um poderoso sistema SOP pode fazer a diferença entre o sucesso e o fracasso de um ciclo SOP (planeamento de vendas). Os sistemas SOP são muito úteis para quadros superiores, uma vez que permitem uma visão geral da saúde de toda a organização. Com as suas representações gráficas e “*dashboards*”, um sistema SOP é actualmente um instrumento indispensável para qualquer empresa.

O mercado de software está-se a tornar cada vez mais competitivo, o que está a ter um efeito positivo sobre os produtos SOP disponíveis. Hoje, os sistemas SOP possuem muitos recursos avançados, como “*data-flows*” em tempo real e interfaces de utilizador muito intuitivas. Há uns anos atrás, muitos recursos como estes eram considerados desejáveis, mas hoje eles são essenciais. Além disso, os fornecedores têm racionalizado os seus produtos para que as implementações sejam cada vez mais fáceis, fazendo com que uma aplicação SOP seja mais atraente. Hoje, a implementação de uma típica aplicação SOP, supondo que a empresa já dispõe de um ERP, um SCM e ferramentas de BI, deve demorar cerca de três meses.

Standard Key Performance Indicator's e métricas já construídas num sistema SOP são um recurso muito útil, que oferece benefícios óbvios para qualquer empresa. KPIs e métricas podem ser baseadas em modelos populares, como o modelo “*Supply Chain Operations Reference*” (SCOR) e podem reduzir drasticamente o tempo de execução de um sistema SOP. A maioria das implementações de sistemas SOP demoram demasiado tempo a elaborar relatórios SCOR baseados em KPIs, sendo esta característica fundamental para qualquer sistema SOP. Se essa capacidade não é suportada pelo sistema SOP, então muito tempo será gasto a identificar KPIs e, em seguida, construir relatórios, sejam financeiros ou operacionais.

Um sistema SOP deve ser capaz de integrar com outros sistemas heterogéneos. A maioria das empresas possui um sistema transaccional, normalmente um ERP. Esses sistemas são ricos em dados que as empresas poderão usar em seu benefício. Um sistema SOP deve ser capaz de extrair dados a partir destes sistemas para mostrar valores realistas de KPIs e de métricas internas, através da aferição de dados históricos.

Um sistema SOP deve também ser capaz de integrar com um sistema SCM. A integração destes dois sistemas da empresa dá a flexibilidade necessária para permitir alterar dados no sistema SOP, se determinados objectivos organizacionais não estão a ser cumpridos. Por

exemplo, um gerente de vendas pode precisar de mudar a previsão de vendas de um determinado produto, a fim de cumprir objectivos organizacionais para esse produto. Com os dois sistemas integrados, em vez de entrar no sistema de SCM para fazer essa mudança, esta pode ser efectuada directamente no sistema SOP, e as informações serão actualizadas no sistema de SCM automaticamente.

Um sistema SOP deve ser capaz de extrair dados de um sistema de BI, tais como dados históricos e métricas. Para isso, o sistema SOP deve estar no topo dos sistemas ERP, BI ou SCM. É preferível que o fluxo de dados a partir destes sistemas seja bidireccional, mas ainda hoje, em alguns casos, as limitações tecnológicas restringem severamente o fluxo bidireccional. Por exemplo, os dados alterados num sistema SOP não podem ser actualizados automaticamente num sistema de BI. Para um sistema SOP ter esta capacidade, deve ser construído sobre uma plataforma que possa integrar sistemas heterogéneos. Esta deve ser uma característica fundamental de um sistema SOP.

No caso de um sistema SOP “*stand-alone*”, o sistema deverá ser capaz de carregar os dados de arquivos directamente, tanto os dados transaccionais como os dados históricos. O sistema deve também ser capaz de fazer a leitura dos dados em arquivos, e então carregá-los de volta para o ERP, BI, SCM, e outros sistemas (ver Figura 3).

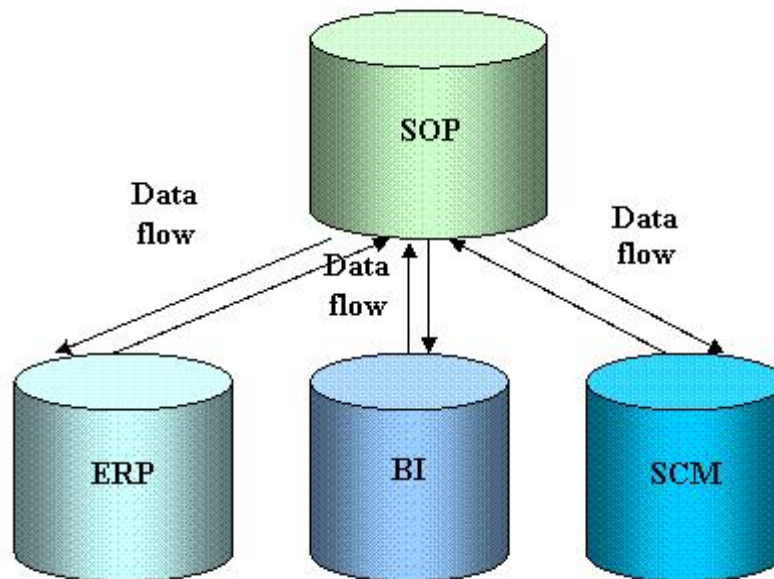


Figura.3: Diagrama SOP

O detalhe das características de um sistema SOP é muito importante, pois é este detalhe que determina como os gestores podem ver os KPIs a vários níveis, podendo então tomar as acções apropriadas rapidamente, se for necessário. O gestor, por exemplo, pode olhar para um inventário, a nível nacional, regional ou ao nível de uma sucursal. O detalhe das características aumenta a eficácia de um sistema SOP.

A criação de hierarquias pode reforçar o poder de um sistema SOP. As hierarquias podem ser construídas directamente num sistema SOP, ou podem ser importadas de outros sistemas, como sistemas ERP ou SCM. Se a hierarquia é construída directamente no sistema SOP, então deverá ser possível mapear a hierarquia SOP com a hierarquia do SCM e do ERP.

O número de dimensões de uma hierarquia que pode ser construído num sistema SOP é limitado. As dimensões mais utilizadas entre as indústrias são três: o produto, o cliente, e as dimensões geográficas. A habilidade de modificar essas hierarquias é importante, pois elas podem mudar à medida que a empresa cresce, ou se a natureza do negócio muda. No ambiente competitivo de hoje, mudanças como essas podem ser frequentes, e as eventuais restrições no sistema SOP poderá ser visto negativamente pela empresa utilizadora.

As características discutidas acima permitem ao sistema SOP realizar simulações utilizando diferentes valores (por exemplo, receitas versus objetivos). As simulações utilizadas pelo SOP também ajudam a monitorar KPIs em diferentes cenários empresariais. Assim, o SOP pode simular cenários diferentes, permitindo retirar conclusões sobre determinada situação. Por exemplo, após o valores dos KPI serem fixados pela gestão de topo, podem ser discriminados para os outros níveis utilizando a hierarquia que foi incorporada no sistema SOP. O inverso também pode ser conseguido. Esta característica é muito importante porque ajuda a gestão de topo no teste de vários cenários.

Os mais avançados sistemas de SOP possuem ainda tarefas para gestão de módulos. Estes módulos podem ter fluxos de dados incorporados que são integrados como gestores de tarefas. Assim, o sistema pode enviar correio electrónico para a próxima pessoa do fluxo de trabalho para realizar uma tarefa específica, após a tarefa anterior ter sido concluída. Também é possível monitorar o estado de uma tarefa, mostrando qual a percentagem entretanto concluída, o que dá uma representação visual do volume de trabalho que ainda resta fazer. As tarefas podem ser construídas hierarquicamente, o que permite, assim, definir tarefas a vários níveis. Estes níveis podem ser mapeados para os níveis na hierarquia da empresa. Uma hierarquia de tarefas também ajuda a coordenar as diversas tarefas do planeamento SOP como um todo.

SOP auxilia as empresas a definir o seu plano tático, após ter sido efectuado o planeamento estratégico. Um amplo sistema SOP pode simplificar o ciclo do planeamento e de fluxo de informação entre diferentes entidades dentro da empresa. Os sistemas SOP estão em evolução lenta em sistemas complexos, à medida que novas funcionalidades são constantemente adicionadas. Os sistemas SOP são hoje uma parte integrante de qualquer empresa. Em alguns casos, as funcionalidades básicas de um sistema SOP são fornecidas com um sistema transaccional (ERP) ou um sistema de SCM. Estas funcionalidades cobrem os requisitos básicos de uma empresa, mas estão muito aquém de um verdadeiro sistema SOP.

2.4.2 Casos de estudo de ERPs existentes

Nesta secção é apresentado e analisado um sistema ERP bem conceituado no mercado, o SAP.

O ERP da SAP, fornece características e funções para análise operacional que auxiliam a otimizar toda a cadeia de abastecimento, a melhorar as receitas e aumentar a satisfação do cliente. A solução inclui funcionalidades e funções que suportam as seguintes actividades:

- Acompanhamento de aquisições - Monitoriza as operações de compra sendo fornecida uma análise detalhada das actividades e processos de compra.
- Inventário e gestão de armazéns - Avalia o stock real da organização, baseado em critérios de quantidade e de valor. Analisa as actividades dos armazéns, tais como o fluxo físico de materiais e cargas.

Revisão Bibliográfica

- Relatórios da produção - Fornece diversos relatórios padrão e análises de produção detalhando informações relacionadas.
- Análise do cumprimento de encomendas - Avalia e melhora o cumprimento das encomendas, utilizando indicadores chave de desempenho (KPIs) para transporte e gestão de encomendas, medidas de desempenho estratégico ou estatísticas necessárias para a otimização da cadeia de abastecimento.
- Análise dos serviços de apoio ao cliente – Monitoriza as tendências financeiras, custos e receitas por cliente, bem como contratos de prestação de serviços. A solução também suporta análises de base, e proporciona análises de garantias do cliente.
- Programa de gestão do projecto - Monitoriza e controla projectos de dados e avaliar projectos, no sentido de tentar otimizar custos do produto.
- Gestão da qualidade – Permite o planeamento, recolha e avaliação dos custos relacionados com a qualidade. A solução inclui funcionalidades de gestão da qualidade que fornecem dados para determinar pontuações definindo padrões de qualidade.
- “*Enterprise Asset Management*” - Realiza avaliações estratégicas, incluindo análises do tempo médio por reparação (MTTR) e tempo médio entre reparações (MTBR).
- Planeamento de vendas - Define metas de vendas, usando múltiplas dimensões e principais características, integra e consolida o planeamento das vendas e o planeamento de marketing. A solução permite a gestão do território, de acordo com regiões, linhas de produtos, ou outras variáveis, bem como a oportunidade de planeamento e análise de parceiros.
- Análises de vendas - Apresenta a organização das vendas com uma visão precisa do desempenho actual das vendas e uma visão geral da eficácia da força de vendas.

A infra-estrutura de TI e processos de negócio apoiam o crescimento da empresa. Mas como se sustenta um crescimento rentável? Com dinâmica global competitiva, que é o novo desafio. Como é que se:

- Fabrica com precisão e eficiência
- Gere o inesperado, com falta de material para as pressas/imposições do cliente
- Aperta a cadeia de abastecimento e racionaliza processos para reduzir custos, melhora a margem, e fortalece a posição competitiva
- Disponibiliza um serviço superior que constrói relacionamentos de longa duração
- Acelera a introdução de novos produtos

A funcionalidade de gestão de relacionamento com clientes do SAP “*Business All-in-One*” ajuda as médias empresas a melhorar o marketing, vendas e gestão dos serviços. A integração com as funcionalidades do ERP ajuda a reter clientes, através de processos de negócio: otimizando recursos e melhorando a segmentação de marketing para impulsionar a procura; permitindo a visão relativa a todas as informações dos clientes; gerindo ciclos de vendas para ganhar mais negócios e prestando serviços de excelência que permitem manter clientes e aumentar as receitas de serviço. Análises robustas proporcionam também a visibilidade em tempo real dos principais indicadores de desempenho em todas as funções.

As empresas têm crescido rapidamente, os processos que funcionavam bem antes podem parecer pesados e ineficientes hoje. Isso significa novos desafios e novas oportunidades. Como se pode afinar operações para reduzir custos e eliminar erros? Como se pode continuar a proporcionar melhores produtos, serviços e apoio do que os concorrentes? Como se identifica, adquire e conserva clientes - e se mantêm as vendas no alvo para financiar o crescimento -

enquanto se cumpre todas as outras metas? Estas perguntas mantêm qualquer um acordado durante a noite. As funcionalidades de um CRM podem ajudar. Normalmente são pré configurados para satisfazer as necessidades do rápido crescimento das médias empresas, prevendo uma visão de 360 graus dos clientes, gerando informações para agilizar os fechos dos negócios. Pode-se impulsionar a procura dos clientes e aumentar o ROI otimizando os recursos no mercado, executar campanhas, organizar e gerir o fecho de novos negócios.

2.5 *Data Mining*

Na avaliação e selecção do software, a criação de valor está na qualidade, informação imparcial sobre os fornecedores, sobre os seus produtos e serviços. O desperdício é o tempo excessivo por vezes gasto na recolha e avaliação de informações. Uma empresa não deve sacrificar a qualidade da informação para tentar reduzir estes desperdícios. Em vez disso, deve retirar as acções que não criam valor e agilizar aquelas que permitem uma solução adequada para ser implementada.

“*Data Mining*” significa usar de forma eficiente dados que foram recolhidos para análise, isto é, olhar para os padrões, tendências e oportunidades, e ir o mais longe possível retirando conclusões fundamentadas para fornecer “feedback” aos processos empresariais.

“*Data mining*” num ERP (que também pode ser considerado BI (“*Business Intelligence*”)) é um tópico extenso e modular. Na banca, por exemplo, é utilizado “*Data Mining*” em tempo real para determinar os padrões de crédito e débito das transacções, olhando para possíveis utilizações fraudulentas. Também é usado para procurar anomalias nas transferências de fundos, olhando principalmente para a fraude. “*Data Mining*” no sector bancário é usado para procurar transacções comerciais anormais, como transacções sem crédito, para analisar dados históricos, para pesquisar tendências de mercado, para realizar exames de rentabilidade do serviço, e muitas mais operações.

Em vendas, “*Data Mining*” é usado na análise do desempenho dos vendedores, clientes e compradores, bem como a evolução das vendas de produtos, garantias, mercados e rentabilidade.

Qualquer indústria possui interesse na extracção e análise destes dados. A nível técnico, a construção de armazéns de dados permite apresentar informações que vão ser analisadas estatisticamente, com base em colheita de informações do sistema ERP. A nível empresarial (que impulsiona o nível técnico), as informações são analisadas para prever o lucro, atendimento ao cliente, ou a segurança.

O uso de sistemas ERP e CRM gera inevitavelmente enormes quantidades de dados. Estes dados requerem armazenamento e métodos apropriados para a sua recuperação, extracção e manipulação de forma manejável para fins de análise. O resultado da resposta a estes requisitos foi a criação de uma área conhecida como “*Business Intelligence*” (BI). Através da utilização de BI, tanto organizações públicas como privadas, podem aplicar técnicas (“*data mining*”) para identificar as tendências, a demografia, as preferências dos consumidores, os padrões, ou para orientar a publicidade de um produto ou serviço relevante para um determinado segmento populacional.

Algumas das aplicações mais populares do conceito de “*Data Mining*” são as seguintes:

Detecção de fraudes

Análise da qualidade de defeitos

“*Supply Chain Management (SCM)*”

Contratação com especificidades

A criação de valor que “*Data Mining*” e “*Business Intelligence*” podem representar numa empresa é a capacidade de identificar tendências e mudanças nos padrões de procura por parte dos clientes, isto é, a capacidade de perceber as necessidades actuais (ou tendências) dos clientes. Tal facto pode ajudar as empresas na gestão dos seus processos, reduzindo custos, aumentando as receitas das vendas e criando novas oportunidades de negócio.

O conceito de “*Data Mining*” pode ser, e é, usado com vantagem em ERPs a vários níveis.

No que diz respeito à extracção de dados num ERP, muitas empresas estão a transformar o que é conhecido como “fabrico analítico”. Representa uma solução de BI, uma camada acima das tecnologias de fabrico tradicional, permitindo que os utilizadores extraiam dados do seu ambiente de fabrico. O que significa isso exactamente? Digamos, por exemplo, que um fabricante produz automóveis e necessita de adquirir peças para veículos automóveis a partir de múltiplos fornecedores. Se estes componentes não chegam a tempo, isto irá afectar negativamente a sua produção. Fazendo uso de técnicas de “*Data Mining*” num sistema ERP, o fabricante pode optimizar os seus processos de fabrico, pois pode:

- Distinguir quais dos seus fornecedores não cumpre os prazos de entrega dos componentes (e, portanto, optar por outro fornecedor).
- Decidir se diferentes processos de fabrico podem ser realizados antes da chegada dos componentes, de forma a não perder tempo na produção.

O uso de “*Data Mining*” num ambiente ERP pode também ajudar a reduzir os custos no âmbito da secção financeira, bem como ajudar a extrair informações importantes para os gestores de recursos humanos sobre os trabalhadores da empresa. Por exemplo, se uma especificidade é necessária para uma tarefa de fabrico, o gestor de recursos humanos pode rapidamente levantar essas informações e ter uma decisão acertada sobre se o empregado tem as habilitações mais adequadas para essa tarefa.

Ao longo da última década, a Internet mudou a forma como as organizações fazem os negócios. Com o advento da Internet, os dados transaccionados atingiram enormes proporções. Vamos enfrentá-lo, os dados são perpétuos. Então a questão é: como podem as empresas utilizar em seu favor os dados transaccionados? “*Data Mining*” (o processo de obter informação) é vital para compreender o que está a acontecer dentro da empresa, como ela está a evoluir financeiramente, onde residem os problemas, e onde podem ser introduzidas melhorias. Como tal, é importante ser capaz de capturar dados de forma segura e eficaz, a fim de tomar as decisões empresariais estratégicas.

Os volumes de dados com que as empresas lidam diariamente, observam determinados regulamentos, a que estas devem aderir, bem como políticas operacionais organizacionais que lhes são impostas. Estes são apenas alguns dos requisitos que obrigam a um controlo de dados.

A mais recente tendência de “*Data Mining*” é o CCM (“Continuous Control Monitoring”). As poderosas capacidades analíticas do CCM permitem às empresas um ganho imediato subjacente às transacções dos seus negócios e relatórios financeiros.

Um exemplo de onde é usado CCM é o seguinte:

Uma interface CCM para o inventário em participações num negócio de distribuição, que é utilizado para analisar eventuais acções em milhares de referências em stock. Utilizando um caso específico, o sistema reconhece que, de acordo com as projecções, em 10 semanas o produto estaria sem stock, e o tempo de reposição é de oito semanas. O sistema CCM determina o melhor método para encomendar, a quantidade óptima, e prepara uma ordem de compra para aprovação.

O que torna o CCM diferente? Por uma contínua e independente análise de dados financeiros, as aplicações CCM podem verificar e validar os dados contra a organização do controle de parâmetros e regras comerciais. O CCM permite às empresas analisar rapidamente grandes volumes de dados, identificando actividades suspeitas, e fornecendo indicações sobre onde possa ocorrer qualquer violação de segurança. Esta funcionalidade permite aos utilizadores detectar a operação específica responsável, antes de o problema piorar. Em seguida, armazena automaticamente os dados que estão a ser analisados, resultando em informações que podem ser facilmente pesquisadas e instantaneamente recuperadas.

A recente proliferação de recolha de dados acessível a partir de suportes de armazenamento e de poderosos sistemas de computação tem fornecido uma base sólida para o surgimento de “*Data Mining*”. O principal objectivo deste rápido crescimento é a análise de um largo, e muitas vezes heterogéneo e distribuído, conjunto de dados a fim de descobrir informações úteis sobre os fenómenos ou sistemas que geraram esses dados. Essas fontes de dados podem vir de vários fenómenos naturais ou de sistemas artificiais. Podem ser encontrados exemplos da existência de volumes enormes de dados em áreas tão diversas como meteorologia, ciências da terra, astronomia, biologia, ciências sociais, etc.

Em particular, note-se que existe outra fonte de dados obtida principalmente a partir de negócios e actividades industriais. Este tipo de dados é conhecido como “Dados Empresariais”. A partir da análise destes dados, o analista pretende conseguir delinear uma concepção mais estratégica, para otimizar o desempenho de algum tipo de medida, como a redução dos tempos de produção, a melhoria da qualidade, a eliminação dos resíduos e a maximização dos lucros. A análise dos dados pode descrever diferentes cenários num ambiente de fabrico, no controlo de qualidade de algum processo, na detecção de alguma falha no diagnóstico do funcionamento de uma máquina ou processo, na análise de risco de crédito, na gestão das cadeias de aprovisionamentos dum sistema de fabrico ou na tomada de decisões num determinado negócio, só para citar alguns exemplos.

O uso de “*Data Mining*” e a consequente descoberta de novo conhecimento, podem ser agrupados em diferentes categorias, dependendo do tipo de métodos e algoritmos utilizados. Assim, podemos ter métodos que se baseiam em redes neuronais artificiais (RNAs), em análise de agrupamentos, em árvores de decisão, na associação de regras, em algoritmos genéticos, em regras de indução, etc. Há vantagens e desvantagens associadas a cada método que dependem de situações ou aplicações específicas, e é sabido que nenhum método domina os outros métodos, o tempo todo. Uma questão crítica é a decisão de qual o método escolher para uma determinada aplicação.

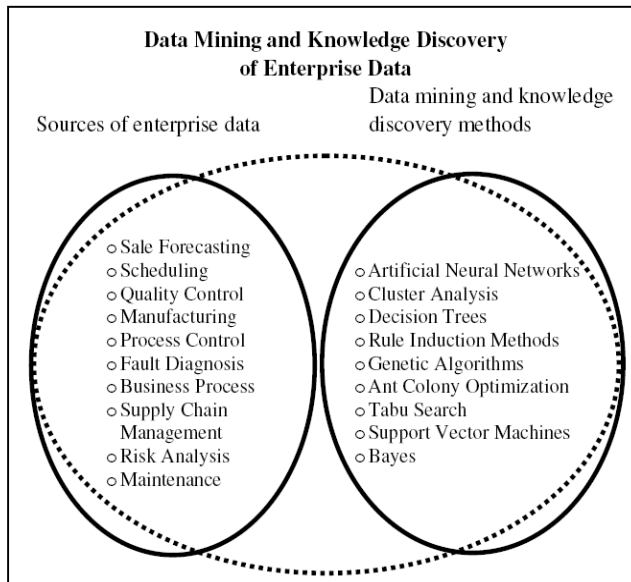


Figura 4: “Data Mining” e descoberta de conhecimento numa empresa

Geralmente, “Data Mining” (algumas vezes chamado de descoberta de conhecimento) é o processo de análise dos dados a partir de diferentes perspectivas, resumindo-os em informação útil - informação que pode ser utilizada para aumentar a receita, reduzir os custos, ou ambos numa organização.

Os dados são quaisquer factos, números ou texto que podem ser tratados por um computador. Hoje, as organizações estão a acumular crescentes quantidades de dados em formatos diferentes e de diferentes bases de dados. Estas incluem: dados transaccionais ou operacionais, tais como, vendas, custos, inventários, folhas de pagamento, contabilidade etc.

Os padrões, associações ou relações entre tudo isto podem fornecer informações muito úteis. Por exemplo, a análise das transacções de um ponto de venda de retalho pode produzir informações sobre quais produtos que estão a ser vendidos e quando.

A informação pode ser transformada em conhecimento baseado em padrões históricos e tendências futuras. Por exemplo, o resumo das informações sobre as vendas a retalho de um supermercado pode ser analisado à luz dos esforços promocionais para fornecer conhecimento sobre o comportamento de compras de um consumidor. Assim, um fabricante ou revendedor poderia determinar quais os produtos mais favoráveis a um esforço promocional.

Dado um conjunto de amostras deverá ser partidas em grupos similares de amostras, de acordo com alguns critérios de similaridade.

Devemos determinar classes de amostras para ensaio utilizando classificações conhecidas para classificar os dados dos ensaios.

Para cada uma das categorias, devemos seleccionar um subconjunto das características responsáveis pela criação do estado correspondente à classe (que é também um tipo específico de redução de dimensão).

Algumas das amostras não são boas representantes de qualquer das classes, portanto, é melhor ignorá-las durante a fase de “Data Mining”

As técnicas habitualmente utilizadas por “Data Mining” são:

Revisão Bibliográfica

- Redes neuronais, que são modelos preditivos não lineares, que aprendem através do treino e se assemelham a estruturas de redes biológicas neuronais.

- Árvores de decisão, que são estruturas em forma de árvore, que representam conjuntos de decisões. Estas decisões podem gerar regras para a classificação de um conjunto de dados.

As redes neuronais são um dos ramos da inteligência artificial. As redes neuronais são maciçamente utilizadas em processamento distribuído paralelamente, que tem a propensão natural para armazenar conhecimento experimental e torná-lo disponível para uso. O processo de decisão das redes neuronais é constituído por duas fases: aprendizagem e raciocínio. Antes de uma decisão ser tomada, as redes neuronais precisam de ser treinadas com avaliações anteriores, como exemplo temos o algoritmo “*Back-Propagation*”. Durante a aprendizagem um exemplo de cada vez pode ser apresentado à rede, e é propagado de forma a calcular os valores de saída. O erro entre os valores alvo é calculado e determinado.

O erro formado por todos os registos é, então, propagado através da rede, a fim de ajustar os pesos, com o objectivo de reduzir o próximo erro. A aprendizagem é feita iterativamente através do ajustar dos pesos, até se atingir o erro mínimo aceitável, fixado anteriormente pelo utilizador. Depois da aprendizagem, o conhecimento para a tomada de decisão é mantido implicitamente no peso das conexões. Está então o conjunto treinado e pronto para resolver um caso novo.

A utilização de redes neuronais para resolver problemas não lineares complexos, não constitui novidade. Algumas das aplicações presentes no mercado envolvendo estas tecnologias são a detecção de fraudes em cartões de crédito, reconhecimento na escrita de caracteres e detecção de culpa em situações de condução de automóveis. Apesar da grande variedade de aplicações, todas elas podem ser categorizadas como problemas padrão.

Por outro lado, “*Data Mining*” é uma nova área, introduzida em 1993 por Agrawal, Imielinske e Swami, a partir de uma base de dados de vendas de uma organização. A aplicação é conhecida como “*Market Basket Analysis*”. No entanto, “*Data Mining*” continua a ser usado para resolver tarefas de classificação, extraindo regras entre as relações dos atributos em previsão e metas.

Alguns autores têm proposto um novo modelo geral CBA (“*Classification Based Association*”), que consiste em duas partes, uma regra gerada, CBA-RG, que se baseia num algoritmo à priori e um construtor de classificações, CBA-CB, que é baseado num algoritmo ingénuo. Podem-se usar estes algoritmos também para construir um modelo de detecção de intrusos. O objectivo é ser capaz de aprender as regras, que capturar com precisão, do comportamento dos intrusos.

Embora a rede neuronal seja eficiente na resolução de problemas complexos não lineares, a tomada de decisão efectuada por redes neuronais é vaga. Para tornar o resultado das redes neuronais mais convincente, utilizam-se bases de dados com a utilização de algoritmos *a priori* no sentido de produzir conhecimento ou regras.

As redes neuronais são responsáveis por avaliar um caso novo automaticamente, de modo correcto e inteligente. No entanto, para evitar riscos em caso de decisão errada, que não é notificado pela rede neuronal, um algoritmo de “*Data Mining*” é usado para enriquecer o conhecimento / regras a partir da base de dados para validar a decisão da rede neuronal.

A fim de tornar célere a tomada de decisões, estão a ser utilizadas em muitas empresas, técnicas de “*Data Mining*” para automatizar os processos de tomada de decisão. Esta

arquitectura híbrida, “*Intelligent Database Engine*” (IDE), tem a capacidade de fazer e apoiar as decisões adequadamente para uma variedade de bases de dados.

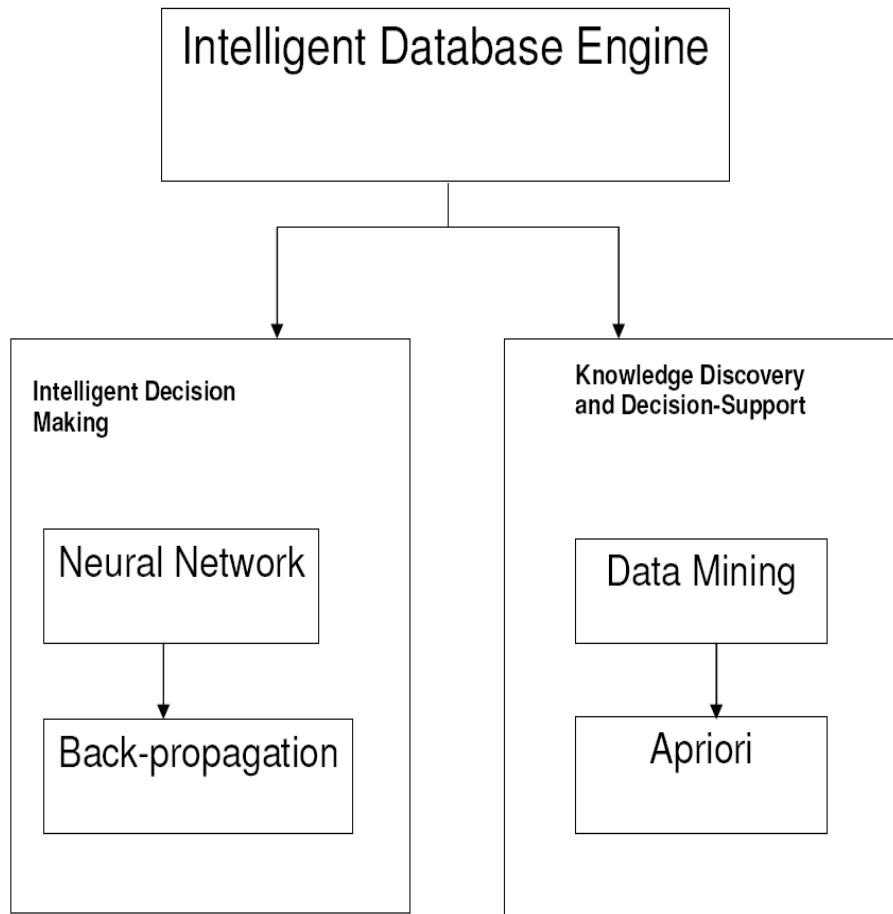


Figura 5: Arquitectura híbrida IDE

A Figura 5 identifica a arquitectura híbrida de um IDE, a rede só é capaz de inferir um resultado sem dar qualquer explicação para a decisão. Para apoiar o resultado, “Apriori” irá produzir um conjunto de regras para cada resultado das classes da rede neuronal. Se as regras são da mesma categoria que o resultado da classe conclui-se que o resultado da rede neuronal é credível e implicitamente expressas pelas regras destacadas.




Figura 6: Exemplo de uma rede neuronal

A Figura 6 representa um exemplo de uma rede neuronal, que pode ser aplicada ao caso de estudo deste projecto em que as entradas são bem conhecidas, mas a forma de combinar o peso

ainda não é completamente conhecido. As saídas são bem conhecidas. A experiência está disponível (lotes de formação de dados). O treino apresenta exemplos conhecidos (dados de vendas anteriores) à rede para que possa aprender como calcular as previsões venda, teremos então de iterativamente ajustar pesos para encontrar as melhores previsões de vendas mensais para o ano seguinte. (minimizando os erros).

As entradas devem normalmente ser padronizadas ou redimensionadas, para evitar entradas com grandes gamas de valores dominando a rede.

Cada iteração (ajustando os pesos) é normalmente chamada de geração. A geração final chega quando não se pode reduzir a taxa de erro adicional e a formação de dados encaixa-se melhor, mas provavelmente pode ultrapassar os valores pretendidos. A geração anterior pode efectuar a validação de dados de forma a encaixar melhor com o resultado esperado. As redes neuronais direccionadas para “*Data Mining*” (classificação ou previsão) podem:

- Identificar entradas / saídas;
- Padronizar os dados;
- Configurar a topologia de rede;
- Treinar a rede com a utilização de amostras;
- Utilizar a validação amostra para seleccionar pesos que minimizem os erros;
- Avaliar o modelo final utilizando amostras;
- Implantar o modelo para efectuar previsões de saída conhecidas as entradas.

2.5.1 KDD

O KDD (“*Knowledge Discovery in Databases*”) é um paradigma, utilizando processos passo a passo, para encontrar padrões interessantes em grandes quantidades de dados. “*Data mining*” é um passo no processo. Grandes bases de dados são cada vez mais comuns nas organizações. Os computadores estão cada vez mais baratos e com maior capacidade de armazenamento, o que tem contribuído para a proliferação dessas bases de dados, numa grande gama de áreas. Análises científicas podem produzir terabytes de informação e produzir taxas de dados a taxas atingindo gigabytes por hora. Informações de pontos de venda, registos governamentais, registos médicos e dados dos cartões de crédito, são apenas algumas outras áreas que podem produzir esta explosão de informação. Não há só maiores bases de dados, mas as próprias bases de dados vão ficando maiores.

É muito mais fácil armazenar dados do que fazer com que eles façam sentido. Ser capaz de encontrar relações em grandes quantidades de dados armazenados, pode conduzir a uma melhoria das estratégias de análise em domínios como o marketing, vendas e análise dos dados em geral. O problema em KDD consiste em encontrar padrões nestas quantidades enormes de dados. Tradicionalmente os dados foram analisados manualmente, mas existem limites humanos. As grandes bases de dados oferecem demasiados dados para analisar na forma tradicional.

KDD emprega métodos de vários campos, tais como inteligência artificial, aprendizagem de máquinas, padrões de reconhecimento, gestão de dados e design, estatísticas, sistemas periciais e visualização de dados. Ele emprega um modelo de vista mais amplo do que estatísticas e esforça-se por automatizar o processo de análise de dados, incluindo a “arte” da criação de hipóteses. KDD tem sido formalmente definido como "processo não trivial de

identificação de padrões válidos, potencialmente úteis, e, em última instância, compreensíveis, dos dados. KDD é um processo altamente iterativo, com processos passo a passo, conforme a figura seguinte:

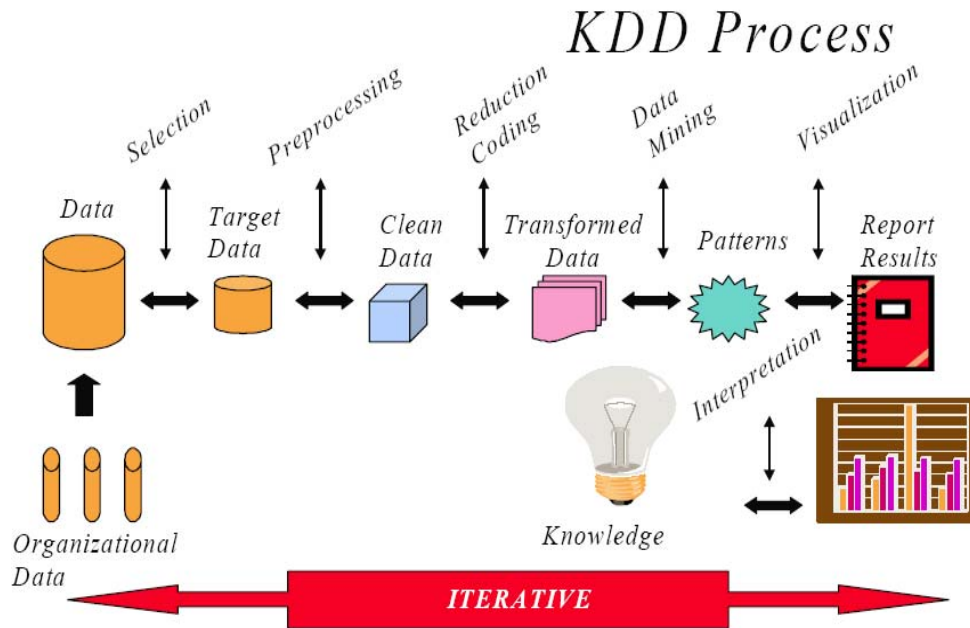


Figura 7: O Processo KDD

Na figura 7, temos presente o processo KDD. Inicialmente temos os dados de uma organização. Estes dados são os dados operacionais recolhidos, em um ou mais locais. Todos os dados operacionais recolhidos são levados para uma localização central. A transformação dos dados resolve as incoerências entre os dados de um local a partir dos outros. Por exemplo, inconsistências podem ser as diferenças nos dados para o mesmo tipo de informação de diferentes nomes de campos para os mesmos campos de dados. Os dados detalhados são utilizados para análises padrão, onde os dados resumidos podem ficar com os resultados das análises anteriores. Uma organização eficiente dos dados é essencial para um eficiente “*Data Mining*”.

Quando os dados estão organizados, um processo de selecção ocorre sempre que algum subconjunto de dados se torna dados de pesquisa, então é realizada uma análise mais aprofundada. É importante ao criar este objectivo que os dados sejam do domínio do analista, e que sejam o que o utilizador final necessita. Às vezes, os dados são recolhidos de uma forma “*ad hoc*”. Na introdução de dados podem ocorrer erros e / ou haver entradas em falta ou desconhecidas. Durante a limpeza dos dados e na fase de pré-processamento algum ruído é removido a partir dos dados.

Uma vez que o objectivo é encontrar padrões raros nos dados, as anomalias podem ser representações desses padrões raros. Devem-se tomar precauções para remover esses tipos de anomalias. Esta etapa do processo pode ser a mais demorada.

“*Data Mining*” constitui um passo no processo KDD. Os dados transformados são utilizados no processo de “*Data Mining*”. É nesta etapa que é efectuada uma busca dos padrões mais interessantes. A pesquisa de padrões é feita num contexto de “*Data Mining*” e o modelo de

representação em que essa análise está a ser executada. É importante, nesta fase, decidir sobre o algoritmo de “*Data Mining*” mais adequado (linear / regressão, redes neuronais, regras de associação, etc.) para a extracção de dados. Os padrões gerados no “*Data Mining*” podem não ser novos ou interessantes. É necessário, portanto, remover padrões redundantes e irrelevantes do conjunto útil dos padrões. Quando um conjunto de padrões bons é descoberto, eles têm de ser comunicados ao utilizador final. Isto pode ser feito textualmente, em forma de relatórios ou usando visualizações, como gráficos, folhas de cálculo ou diagramas, etc. A etapa de interpretação transforma os resultados recolhidos em conhecimento. Esta interpretação pode exigir resolver possíveis conflitos com conhecimento anteriormente descoberto, pode até acontecer estar em conflito com o conhecimento que se acreditava antes de o processo se iniciar. Quando isto é feito para a satisfação do utilizador, o conhecimento é documentado e comunicado a todas as partes interessadas. É importante salientar que o processo de KDD é não linear. Os resultados de uma fase do processo podem ser realimentados para essa fase ou para qualquer outra fase. Os sistemas KDD actuais têm uma componente humana altamente interactiva. Os seres humanos estão envolvidos em todos ou quase todos os processos de KDD. Assim, o processo KDD é altamente interactivo e iterativo.

O “*Data Mining*” é um passo no processo de KDD. É a parte do processo que necessita de mais pesquisa. Os algoritmos de “*Data Mining*” encontram padrões em grandes quantidades de dados, para montagem de modelos, que não são necessariamente modelos estatísticos. Isto é feito dentro de limites computacionais, tais como o tempo (as respostas devem ser encontradas dentro de um quantidade finita de tempo) e o hardware. “*Data Mining*” pode ser utilizado para verificar uma hipótese ou utilizar um método já descoberto para encontrar novos padrões nos dados com que podem fazer novas previsões dos dados ainda não tratados. O termo “*Data Mining*” é recente. Antes “*Data Mining*” era conhecido na literatura como extracção de conhecimento, descoberta de informação, análise exploratória de dados e análise e processamento de dados padrão.

As redes neuronais são um modelo baseado em gráficos sobre o sistema nervoso humano. Trata-se de um sistema de nós conectados organizados em múltiplas camadas. Na Figura 8, vemos que há uma camada de entrada, uma camada escondida (podem haver várias camadas escondidas), e uma camada de saída. As entradas para a rede neuronal são do mesmo tipo dos exemplos de treino das árvores de decisão. Cada nó tem associado um valor de entrada e um peso. Os pesos são multiplicados pelos respectivos valores de entrada e somados.


Neural Networks

Figura 8: Exemplo de uma Rede Neuronal

O resultado de uma função desta soma é o valor a partir do nó de saída que é enviado para a próxima camada de nós. As saídas de uma rede neuronal é um conjunto de pesos que são os coeficientes de uma equação de regressão linear.

Um método para a determinação dos pesos de uma rede é o método “*Back Propagation*”. Este método olha para o erro dos valores de saída das redes e para os valores observados e, em seguida, ajusta os pesos de cada nó de modo a que este erro seja reduzido. Isto é repetido para cada exemplo, alimentando a rede, e repetido várias vezes para todo o conjunto de dados. Assim, é um processo altamente iterativo. Este processo é chamado de "formação" da rede neuronal.

A rede neuronal em si representa uma função de aprendizagem que pode ser usada para prever novos exemplos. A representação do modelo de redes neuronais é difícil de interpretar, em oposição às árvores de decisão, que sabe sempre o que está acontecendo nos nós ocultos. As redes neuronais resultam numa equação de regressão linear, em vez de um conjunto de regras. Embora as redes neuronais possam ser lentas de treinar, uma vez formadas e implementadas, as redes neuronais podem classificar entradas muito rapidamente.

O processo KDD é um bom paradigma para a análise de dados. Pode-se perguntar quais as diferenças entre as tradicionais análises estatísticas e o processo KDD. Os métodos estatísticos empregues pela utilização de KDD têm um rigor semelhante às abordagens estatísticas, mas muitos métodos KDD tendem a ser mais experimentais e menos conservadores do que os utilizados nas estatísticas. Assim, eles são mais adequados para uma "abordagem à descoberta" da análise dos dados.

2.5.2 Regras de Associação

O modelo de representação de árvores de decisão é uma estrutura dos dados em árvore. Tal como na figura 9, em que cada nó da árvore representa um atributo. Os rótulos atribuídos a cada

nó são escolhidos por uma função que pode separar os atributos em que os valores dentro de um nó são mais semelhantes e entre outros nós em que não são tão semelhantes. Diferentes algoritmos de árvores de decisão utilizam funções diferentes para rotular cada nó.

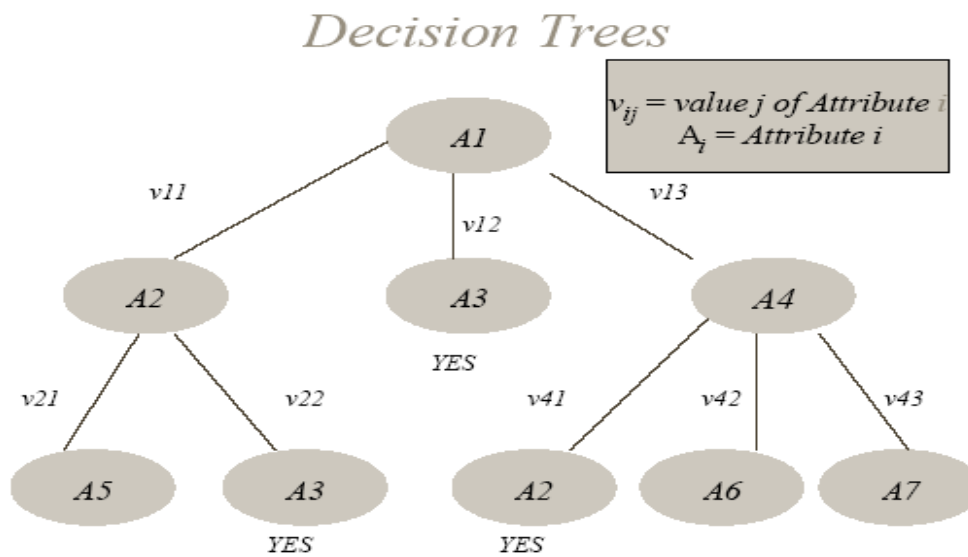


Figura 9: Exemplo de uma Árvore de decisão

O atributo que melhor classifica os exemplos de treino é aquele que rotula o nó. Cada valor do atributo aponta para um nó filho. Os nós tornam-se folhas quando o seu maior atributo medido classifica todos os exemplos de treino desse nó ou todos os atributos tenham rotulado nós. Na Figura 9, A_i fica com um atributo ou variável do conjunto de dados, onde V_{ij} são os valores específicos do algoritmo da árvore de decisão encontrados como bons para esse atributo. A entrada para uma árvore de decisão é um conjunto de exemplos de treino. Os exemplos de treino são os registos a partir de um conjunto de dados onde um atributo, a variável alvo, está correctamente classificado.

Na Figura 9, a formação de exemplos foi classificada com os valores sim ou não. O algoritmo da árvore aprende e generaliza esta classificação e, portanto, pode classificar exemplos ainda não vistos. Um dos inconvenientes das árvores de decisão é que elas podem tender a analisar em excesso os dados. Diferentes algoritmos utilizam diferentes métodos de análise de árvores para compensar isso.

Cada caminho na árvore representa um conjunto de atributos. A árvore é uma disjunção de cada caminho conjuntivo. Pode haver muitas árvores de decisão que podem descrever um determinado conjunto de testes. Habitualmente um algoritmo de uma árvore de decisão pode gerar múltiplas árvores e recomendar a árvore "mais rigorosa" como um classificador. Outro método para "decidir" entre árvores é a utilização destas múltiplas árvores como uma "comissão de peritos" para classificação.

Nas técnicas de "Data Mining" discutidas anteriormente, há situações que favorecem um em relação ao outro. Além disso, cada método tem suas desvantagens. Redes neuronais e árvores são semelhantes na decisão, sendo ambos classificadores. O modelo classificador é construído e é então utilizado para prever o futuro para a classe alvo dos dados não tratados. A vantagem das árvores de decisão sobre as redes neuronais é que as regras de classificação são

lidas directamente a partir do modelo. Muitos analistas de dados não gostam da "caixa negra" do modelo construído pelas redes neuronais. Isto porque o resultado de um modelo de redes neuronais é um conjunto de equações de regressão linear, tornando, assim, as razões para a classificação difíceis de interpretar.

Os modelos de árvores de decisão são mais rápidos de construir. Pode demorar muito tempo para treinar uma rede neuronal. Não obstante, uma vez construída, a execução de um modelo de rede neuronal pode ser mais rápido do que uma árvore de decisão. Em termos de precisão, os estudos revelaram que nenhum método é necessariamente mais preciso que outro. A precisão depende dos dados reais envolvidos.

Os algoritmos com regras de associação / dependência regra mostram concordância de variáveis. Eles tendem a gerar muitas regras, mais do que as árvores de decisão. A vantagem é que estes algoritmos nos dão a capacidade de encontrar padrões de dados raros e menos óbvios.

É importante que os algoritmos de "*Data Mining*" não sejam utilizados de forma "*ad hoc*". O receio é que ao fazê-lo, se possam descobrir padrões sem significado. Na verdade, houve um tempo em que KDD, na comunidade estatística, era considerado de "má reputação".

Também temos de ser cuidadosos quanto à forma como interpretar os padrões que nos são apresentados pelos algoritmos de "*Data Mining*".

É o cérebro humano que serve de modelo, topologia e dinâmicas para as redes neuronais artificiais [Kos92]. As redes neuronais têm se desenvolvido a partir de princípios biológicos neuronais. McCulloch e Pitts [MP93] propuseram o neurónio como um dispositivo binário em tempo discreto. Os neurónios são agora conhecidos por serem mais complicados do que este modelo que opera em tempo contínuo e realizar funções não lineares. Comparando aos computadores, os neurónios são bastante mais lentos, com uma velocidade de cerca de 100 metros / segundo [Rip96]. Para compensar esta falta de velocidade, o cérebro humano é altamente distribuído e massivamente paralelo [Rip96]. Como processos paralelos o cérebro humano é insuperável. O padrão de conexões entre os neurónios revela-se um modelo ideal para a arquitectura de uma rede neuronal [Fau94].

As redes neuronais são essencialmente compostas por três peças: a arquitectura ou modelo; o algoritmo de aprendizagem e as funções de activação [Fau94].

As redes neurais são programadas ou "treinadas" para armazenar, reconhecer e associar e obter padrões ou entradas de bases de dados, para resolver problemas de optimização combinatoria, para filtrar o ruído da medição de dados, para controlar problemas indefinidos; em resumo, para estimar funções de amostragem quando não sabemos a forma dessas funções. São precisamente estas duas habilidades (padrão de reconhecimento e a função de estimativa) que tornam as redes neuronais tão úteis em "*Data Mining*".

2.5.3 Redes neuronais

As redes neuronais tentam solucionar problemas simulando a actividade do cérebro humano e procurando obter conhecimento através da experiência.

As redes neuronais possuem nós ou unidades de processamento denominadas neurónios. Cada neurónio possui conexões para outros neurónios, para os quais envia e dos quais recebe sinais/informações. Existem também conexões entre os neurónios, com um valor associado que

determina o peso da ligação entre eles, isto é, quão forte ou fraca é a influência de um neurónio sobre o outro.

A rede neuronal pode apresentar diferentes topologias de acordo com a estrutura das ligações entre os neurónios:

- Rede totalmente conectada. Cada um dos neurónios liga-se a todos os outros neurónios da rede.
- Rede de camada única. A rede possui neurónios de entrada e neurónios de saída. Os neurónios de entrada contêm os valores de entrada, isto é, as características usadas para descrever um problema específico. Os neurónios de saída apresentam o resultado do problema
- Rede de múltiplas camadas. Os neurónios estão agrupados em camadas, existindo além das camadas de entrada e saída, uma ou mais camadas intermédias.

As redes neuronais aprendem “por exemplos”, sendo determinados os dados representativos de um problema e invocando em seguida algoritmos treinados de forma a aprender a estrutura destes dados. Naturalmente que o utilizador tem de ter bons conhecimentos para seleccionar os dados apropriados a um problema específico.

A análise das redes neuronais é agora centrada nas redes multi-camada, por ser esta a topologia usada neste projecto. De entre estas, usa-se a rede multi-camada “*feed-forward*”. Neste tipo de redes neuronais, cada neurónio de uma camada possui unicamente conexões para todos os outros neurónios da camada seguinte.

Uma rede multi-camada “*feed-forward*”, com uma adequada estrutura de pesos, pode ser usada para modelar alguns mapeamentos entre conjuntos de variáveis de entrada e saída.




Figura 10: Rede “*feed-forward*”

A Figura 10 mostra um exemplo de uma rede com arquitectura “*feed-forward*”, com três unidades de saída e uma camada oculta, que pode ser formada usando “*back-propagation*”. Os nós sombreados da figura são unidades de transformação. As setas de conexão entre as diferentes unidades representam pesos. O algoritmo de aprendizagem “*back-propagation*” é formulado como uma pesquisa no espaço do padrão de pesos, W , a fim de encontrar uma

configuração óptima, W^* , o que minimiza uma função de erro ou de custo, $E(W)$. O padrão de pesos determina como a rede irá responder a qualquer entrada arbitrária. O erro ou custo da função é definida assim:

$$E = \frac{1}{2} \sum_i \sum_p (t_{ip} - o_{ip})^2$$

Esta função compara um valor de saída O_{ip} para um valor desejado t_{ip} , a partir dos vectores p que têm “conhecimento” e das unidades de saída i . O método do gradiente de descida é utilizado para procurar o mínimo deste erro através da função iterativa:

$$W(k+1) = W(k) - \eta \nabla E$$

onde η é a taxa de aprendizagem, e ∇E é uma estimativa do gradiente de E em relação a W .

Há já muitos anos, muitas empresas estão a tentar automatizar os processos de tomada de decisão através da aplicação de ferramentas analíticas. Estas incluem técnicas inteligentes, de que são um exemplo as redes neuronais. Está provado que estas técnicas são bastante eficazes para aprendizagem de conhecimento através da experiência. Por estes motivos, líderes de empresas como a IBM, Microsoft, Siemens, etc., usam redes neuronais para as suas tomadas de decisão.

Apesar de as redes neuronais serem excelentes na resolução de problemas complexos, devido ao facto do conhecimento adquirido pela rede neuronal ser inerente à sua própria arquitectura (activação de funções ocultas e de saída de cada unidade e um conjunto de pesos), podem os humanos não compreender por que razão, ou como uma decisão é tomada. Esta dúvida inibe a confiança, a aceitação e a aplicação da rede neuronal.

Como é que as redes neuronais aprendem?

- Aprendem com a utilização do método “*Back Propagation*” (alimentando as classificações e efectuando a previsão dos erros de volta, ajustando os pesos para reduzir os erros)

- Utilizando métodos alternativos, como por exemplo, o do gradiente conjugado

- Depois de um certo número de iterações, os erros e os pesos deixam de mudar e então o algoritmo pára.

- Podem ser usados parâmetros de calibração como a taxa de aprendizagem (análise do gradiente de descida) ou como a análise da mudança de pesos.

Devem ser utilizadas heurísticas para a rede neuronal, tais como:

- camadas escondidas e nós por camada;

- tentativa erro;

- valores muito baixos respondem?

- com valores muito altos podem-se reconhecer mais padrões, mas pode ser excessivo;

- Tipificar os parâmetros para teste (pelo menos 30 por peso, por exemplo, para 15 entradas, uma camada oculta com 10 nós e uma saída => $30 [10 (15 +1) + (10 +1)] = 5.130$ observações;

- Taxa de aprendizagem entre 0.1 e 0.9: começar com taxa elevada e em seguida diminuir o passo do tamanho da descida do gradiente;

- A alteração das dinâmicas dos pesos permite à rede encontrar uma solução mais rapidamente.

Revisão Bibliográfica

Para escolher a formação das amostras devemos:

- Cobertura dos valores de todos os recursos (entradas e saídas);
- Número de recursos (selecção da variável): por exemplo, utilizar conhecimento, intuição ou métodos como árvores de decisão em primeiro lugar;
- Tamanho do conjunto para treino;
- As proporções das categorias de saída (talvez considerar sobre amostragem).

Como preparar os dados?

- utilizar valores quantitativos contínuos;
- transformar ou padronizar para um mapeamento do tipo (-1, +1));
- utilizar valores inteiros ordenados;
- utilizar valores qualitativos em categorias;
- necessitando de datas ou endereços devemos ter outros tipos de cuidados no manuseamento dos mesmos.

Ao interpretar os resultados devemos converter as saídas para previsões quantitativas para a previsão da rede ou para a probabilidade da classificação da rede.

Devemos utilizar redes neuronais para séries temporais. As redes neuronais são difíceis de entender, mas a análise da sua sensibilidade pode oferecer bons resultados para efeitos de entrada num conjunto de testes.

Os analistas mais experientes empregam muitos dos métodos que são utilizados em “*Data Mining*”, quando analisam dados. Estes incluem modelos estatísticos, tais como regressão linear e logarítmica, análise de agrupamentos, análise gráfica e visualizações. Existem alguns algoritmos empregues em “*Data Mining*” que não são normalmente utilizados pelos analistas mais experientes. Árvores de decisão, algoritmos de redes neuronais e algoritmos de associação / dependência podem ser ferramentas analíticas úteis para o desempenho do analista.

A modulação por dependência utiliza métodos para descrever as dependências variáveis e as associações. O resultado deste algoritmo é o que é conhecido como associações ou regras de dependência. Estes algoritmos foram desenvolvidos para efectuar a análise de mercados de dados. Eles identificam grupos de itens no mercado, que os clientes tendem a comprar, em associação com cada um dos outros. Por exemplo, os clientes tendem a comprar sabão, cremes para o corpo e laca para o cabelo ao mesmo tempo.

O suporte de uma regra é o seu significado estatístico do conjunto de dados. A confiança é uma medida da força da regra em relação ao conjunto de dados.

O problema de encontrar regras de associação interessantes foi primeiro explorado por Agrawal. Agrawal decompôs o problema de encontrar regras de associação em duas partes. A primeira centrou-se em encontrar grandes conjuntos de itens. Um grande conjunto de dados é um conjunto de itens que têm o suporte da base de dados maior que o mínimo especificado pelo utilizador. Depois de o grande conjunto de itens ser encontrado, passamos à segunda parte do problema, utilizando esses conjuntos de itens para gerar regras que têm uma confiança superior à mínima definida pelo utilizador.

Encontrar regras a partir de grandes conjuntos de itens é simples. Encontrar grandes conjuntos de itens é um problema exponencial e, portanto, computacionalmente caro de resolver. Agrawal propôs o algoritmo “Apriori” para encontrar grandes conjuntos de itens e as regras de associação para estes conjuntos de itens.

No sentido de utilizar o algoritmo “Apriori” aproveitando o desempenho dos dados do computador, precisamos de converter os dados para valores booleanos. Os algoritmos com regras de associação avaliam os dados que tiverem de valor zero ou um. Um cliente comprou um item (valor = 1) ou não comprou um item (valor = 0). Converter dados numéricos para booleanos envolve encontrar um limite, acima do qual todos os dados passam a um, e abaixo do qual passam a zero.

Segundo Fausett [Fau94] o método “*Back Propagation*” é definido como sendo, "um algoritmo de aprendizagem, multi-camada de redes neuronais, baseado na minimização da média, ou total, do erro ao quadrado. "Treinar uma rede neuronal com o método “*Back Propagation*” é um processo de três etapas ...”. O “*feed-forward*” de formação do padrão de entrada, o cálculo e a realimentação do erro associado, bem como o ajustamento do peso [Fau94]. A figura, retirada de Caudill e Butler [CB93], descreve o processo de “*Back Propagation*”

:




Figura 11: Processo “Back Propagation”

Este é apenas um método de aprendizagem de uma família de métodos de aprendizagem supervisionados por redes neuronais. A finalidade é a de prever uma ou mais variáveis alvo a partir de uma ou mais variáveis de entrada. [Sar94] "a aprendizagem é normalmente supervisionada por alguma forma de regressão". Outro exemplo deste tipo de aprendizagem pode ser o da regressão polinomial, onde aos termos do polinómio são dados pesos constantes.

- Algoritmos do tipo K, que são um dos algoritmos de aprendizagem não supervisionados mais simples, para resolver problemas de agrupamentos. O processo segue uma simples e fácil forma de classificar um determinado conjunto de dados, através de um certo número de clusters fixado *a priori* (assume k).

O poder e a utilidade das redes neuronais têm sido demonstrados em várias aplicações, incluindo a sintetização de voz, problemas de diagnósticos, medicina, negócios e finanças, controlo robótico, processamento de sinais, visão computacional e em muitos outros problemas que se inserem na categoria de padrões de reconhecimento. As redes neuronais são adaptáveis a modelos estatísticos com base em analogias com a estrutura do cérebro. Basicamente, as redes neuronais são construídas a partir de unidades simples, algumas vezes chamadas de neurónios ou células, por analogia com a realidade. Estas unidades estão ligadas por um conjunto de ligações ponderadas. A aprendizagem é normalmente realizada por modificação dos pesos das ligações. Cada unidade corresponde aos códigos ou padrões de uma característica que queremos analisar ou que se deseja utilizar como previsão.

Estas redes organizam-se normalmente em unidades com várias camadas. A primeira camada é chamada de camada de entrada e a última de camada de saída. As camadas intermédias (se as houver) são chamadas de camadas escondidas. A informação a ser analisada é alimentada com os neurónios da primeira camada e depois propagadas para os neurónios da segunda camada para posterior processamento. O resultado deste tratamento é então propagado para a próxima camada e assim sucessivamente, até à última camada. Cada unidade recebe informações provenientes de outras unidades (ou a partir do mundo externo através de dispositivos) e os processos destas informações serão convertidos na saída da unidade.

A camada de entrada tem os atributos que participam na classificação. Os valores de entrada são os valores dos atributos para cada tuplo de dados. O número de nós na camada de entrada é geralmente definido com base em diferentes tipos de domínios de atributos. As camadas ocultas são construídas no processo de aprendizagem, com base nos nós e nos pesos das ligações. Uma rede pode ter uma ou mais camadas escondidas. O número de nós na camada oculta é determinado através de experiências. Nós em demasia pode levar à saturação e poucos nós reduzem a precisão da classificação. O resultado da classificação é a saída de um nó na camada de saída. A camada de saída pode ter um ou mais nós. Tipicamente existe um nó de saída para cada classe.

A cada ligação é atribuído um peso inicial aleatório usado na formação e que pode ser modificado no processo de aprendizagem. O peso inicial é atribuído aos nós escondidos e na camada de saída.

A classificação relativa à formação do conjunto é conhecido *a priori*, e é utilizado para afinar a rede para registos semelhantes no futuro. O somatório dos pesos de activação e respectivas funções são aplicados em cada nó das camadas ocultas e das de saída, até uma saída ser gerada. Compara-se a saída com a saída esperada para a formação dos ensaios. Se as saídas não corresponderem, volta-se às camadas e modifica-se os pesos das ligações (processo de “*Back-Propagation*”). Executa-se a próxima amostra com o mesmo processo. Os pesos irão convergir e o processo pára.

2.5.3.1 Redes Neuronais – Exemplos de Aplicação

O estudo realizado por Alexey Zorin [Zor03], indica que uma rede neuronal é capaz de captar as relações na evolução dos preços ao longo do tempo dos artigos em stock e formular previsões respeitáveis. Esse mesmo estudo indica que o método “*Back-Propagation*” é considerado um "standard" em problemas de muitos domínios, em especial, na previsão.

Um exemplo de aplicação, por parte da indústria, da análise de um elevado volume de informação foi dado pela Wrangler (um fabricante de roupas masculinas), utilizando redes neuronais, num esforço para melhorar a sua reengenharia total na cadeia de abastecimento. Neste estudo, foi utilizada uma rede neuronal “*feed-forward*” para gerar previsões da procura dos clientes, o que permitiria conseguir um bom planeamento da produção. Os resultados mais visíveis deste trabalho foram o aumento do volume de vendas e a diminuição do investimento no stock de produtos quer para a empresa quer para os seus clientes.

Este caso de estudo tem funcionado tão bem que agora os retalhistas partilham a publicidade e os planos de promoção, num esforço para afinar inventários e reconstituições de stock. Actualmente são efectuadas melhores previsões baseadas na procura dos consumidores, registou-se uma melhoria significativa nos processos de produção, grandes reduções nos ciclos de produção, efectuou-se uma reengenharia nos sistemas de distribuição, e está em curso um programa de reaprovisionamento contínuo. Em suma, conseguiu-se neste caso reduzir o inventário, produzir com custos mais baixos, aumentar as vendas e melhorar a rentabilidade da Wrangler.

Outras aplicações conhecidas da utilização de redes neuronais encontram-se na indústria alimentar, em métodos de classificação de frutos, na classificação de frutas e legumes, na classificação de vinhos e na colheita de citrinos por exemplo.

No mercado de fruta fresca, as maçãs são classificadas em categorias de qualidade, de acordo com seu tamanho, cor e forma e para a presença de defeitos. Normalmente a classificação das maçãs por cor é decidido de forma empírica pelos olhos dos trabalhadores. Contudo, é muito difícil distinguir cores individuais, devido ao grau de semelhança da coloração das maçãs. Recentemente, muitos métodos utilizando a visão por máquinas foram proposto para substituir o sentido empírico de classificação pelos olhos dos trabalhadores. A classificação de maçãs usando a visão de máquinas, pode ser arbitrariamente dividida em quatro etapas: a aquisição de imagens, a sua segmentação, sua interpretação e, finalmente, a classificação dos frutos.

Neste estudo foram utilizados dois modelos de redes neuronais. A rede neuronal é utilizada para classificar um pixel, em qualquer parte de uma maçã. A rede neuronal contém três camadas (camada de entrada, camada escondida e camada de saída). A camada de entrada possui sete unidades: R_i , G_i , B_i referente a cada pixel da imagem de dados, a média de dados R , G e B , e ainda a posição do pixel Y no que se refere às coordenadas bidimensionais. A camada oculta possui cinco unidades. A camada de saída possui seis unidades que indicam as condições de julgamento da superfície da maçã.

Em 2004, Leemans e Destain [LD04] propuseram um método de classificação hierárquica com base na presença de defeitos e aplicado a maçãs do tipo “*Jonagold*”. Várias imagens, que cobrem a superfície dos frutos, foram tiradas por uma máquina protótipo. Estas imagens foram então segmentadas e as características dos defeitos extraídas.

Os defeitos foram caracterizados por parâmetros: cinco para a cor, quatro para a forma, cinco para a textura e um para a sua posição. Esta base de dados é uma tabela dinâmica. A tabela

é bastante reduzida para frutos saudáveis, mas incluem mais de uma centena de parâmetros para alguns tipos de defeitos.

Na classificação de vinhos, a avaliação da sua qualidade, desempenha um papel muito importante tanto para o fabrico como para a venda.

Historicamente, a qualidade ou a origem geográfica do vinho foi determinada apenas através de degustação de vinho por peritos. Contudo, mais recentemente, existem instrumentos mais avançados disponíveis. Por conseguinte, parece razoável para determinar o âmbito geográfico das origens do vinho, utilizar, técnicas fiáveis de análise química combinadas com métodos métricos modernos em vez da tradicional prova de vinho dos peritos.

No que diz respeito à análise dos constituintes do vinho, há muitos relatórios que efectuaram a análise dos compostos relativos ao aroma do vinho, para a determinação dos seus constituintes, tais como, ácidos e conservantes.

Linskens e Jackson [LJ93] descreveram vários métodos de análise vinho. Em Sun et al [Sun97], foi utilizado um modelo de redes neuronais de três camadas, utilizando “*Back Propagation*”, para classificar os vinhos em seis amostras de diferentes regiões, com base na medição dos vestígios de B, V, Mn, Fe, Al, Zn, Cu, Sr, Ba, Rb, Na, Mg, K, P, Ca usando um ICP-OES.

Sun [Sun97] mediu em quinze elementos os valores de concentração (mg/L), em dezassete comprimentos de onda diferentes, para cada amostra de vinho, servindo o seu vector de concentração $ap = (ap1, \dots, ap17)$, como entrada padrão. Por isso a camada de entrada continha 17 nós de entrada. A camada de saída contém seis nós, referentes a seis origens geográficas diferentes.

Durante o processo de aprendizagem da rede, uma série de padrões de entrada (ou seja, 17 vectores de concentração) com seus correspondentes padrões de saída esperados (ou seja, a verdadeira classe das amostras de vinho) foram apresentadas à rede para aprendizagem, com a ligação entre os nós com pesos diferentes, ajustados em camadas de uma forma iterativa pelo algoritmo “*Back Propagation*”.

A fim de obter um modelo de redes neuronais óptimo, foram testadas diversas arquitecturas de rede.

Recentemente, Beltrán [Bel06] apresentou os resultados da classificação de vinho tinto chileno, considerando-se as variedades *Cabernet Sauvignon*, *Merlot* e *Carmenère* de diferentes vales, anos e vinha. A classificação foi baseada em informações contidas nos compostos fenólicos. Foram utilizadas diferentes transformadas, incluindo a transformada de *Fourier*, a transformada de *Wavelet*, a classe de perfis de *Fisher*. As transformações foram analisadas em conjunto com vários métodos de classificação, com redes neuronais.

No seu estudo, foram analisados 172 vinhos tintos chilenos. Foram obtidas 80 amostras de vinhos *Cabernet Sauvignon*, 35 de *Merlot* e 57 de *Carmenère*, cultivados em Maipo, Rapel, Curicó, Maule Itata e em vales da zona central do Chile, entre os anos de 2000 e 2001.

Foi utilizado o processo de validação LOO (“*Leave One Out*”), nesse sentido foi deixada uma amostra de fora e o sistema de classificação foi treinado usando as 171 amostras restantes. Em seguida, a amostra que foi deixada de fora, foi apresentada ao classificador para determinar a que classe pertencia. Foi assumido que este procedimento de classificação era o melhor método a ser utilizado nos casos em que a quantidade de informação era baixa, como neste caso. Para cada combinação de características, foram executados 172

testes. Os melhores resultados foram obtidos quando se utilizou como método de extracção o recurso combinado da transformada de *Wavelet* juntamente com o cálculo dos coeficientes de correlação no domínio do tempo domínio da rede neuronal.

As máquinas de visão e o processamento de imagem têm sido cada vez mais utilizados em aplicações agrícolas, especialmente para detecção do estado de culturas e suas colheitas. A estimativa do tamanho do fruto permite obter uma boa ideia da qualidade da produção. O reconhecimento do contorno circular dos frutos tem sido muito investigado e tem muitos domínios de aplicação nas indústrias alimentares.

Uma variedade de classificadores e vários recursos foram utilizados por Goksel e Parrish [GP77], para identificar a fundo das frutas. Foram utilizadas imagens monocromáticas, reforçada por filtros de cor, para identificar as colheitas das maçãs.

Abate e Harrell [AH87], utilizaram a cor das imagens para distinguir os citrinos. O limiar de tonalidade foi encontrado usando curvas de reflexo no espectro de frequência. Foram utilizados outros recursos para tratar o problema da identificação dos citrinos, continuando a cor ser uma das funcionalidades mais utilizadas. O recurso é simples de usar e conduz a bons resultados.

Para além de extrair características diferentes para identificar as frutas, Molto [Mol92] utilizou diferentes classificadores baseados em redes neuronais.

Onyango e Marchant [OM03] descreveram o desempenho de um classificador Bayesiano, em comparação com uma rede neuronal, baseada num classificador de plantas / ervas / de imagens coloridas do solo. Neste estudo, foi usada uma distribuição de probabilidade para efectuar o treino da rede.

Plebe e Grasso [PG00] descrevem o sistema de processamento de imagem para orientar na colheita automática de laranjas, que foi integrado no primeiro protótipo completo de robot para colheita de laranjas.

2.6 Conclusões

Após serem referidos vários temas no estado da arte, tais como “*Data Mining*”, KDD, regras de associação e árvores de decisão, que foram de extrema utilidade no decorrer do projecto, não deveremos ter veleidades quanto à sua forte utilização no desenvolvimento futuro do ERP, principalmente devido ao escasso número de colaboradores actualmente afectos a este projecto.

No entanto o método de redes neuronais “*Back Propagation*”, quer pelas opiniões manifestadas em várias referências bibliográficas consultadas, quer por todos os testes executados no âmbito deste projecto, foi utilizado no desenvolvimento do ERP para efectuar a previsão de vendas do cliente.

3 Especificação do Módulo Comercial ERP jDx

3.1 Descrição do Problema

O problema a tratar está inserido num outro, ainda de maior dimensão, que é o desenvolvimento de um ERP que substitua o Dinamix, sistema desenvolvido no início da década na empresa, e que se encontra ultrapassado tecnologicamente e a vários outros níveis.

Este projecto é então um sub problema do atrás descrito, ou seja, o desenvolvimento em Java, utilizando o *PostgreSql* como motor de base de dados, de um módulo comercial para o ERP da Dinâmica.

Desenvolver um módulo comercial de um ERP, como sabemos, não é uma tarefa fácil nem pequena, havendo constantemente a possibilidade de melhorar o produto desde que inicialmente tenham sido definidas boas práticas de análise e desenvolvimento.

Todas as ferramentas a utilizar são uma novidade tendo sido necessário um estudo prévio antes de se avançar para o desenvolvimento do projecto.

3.2 Módulo Comercial

No desenvolvimento do módulo comercial são tratadas todas as manutenções relativas a documentos comerciais (facturas, guias de remessa, vendas a dinheiro, facturas pró-forma, propostas, notas de crédito, notas de débito, encomendas e guias de transporte). Sempre que os documentos envolvam contas correntes de clientes, procura-se efectuar os respectivos lançamentos.

É também desenvolvido um quadro de bordo, que auxilia a gestão de topo da empresa na obtenção de dados vitais “*on-line*”, nomeadamente o volume de vendas mensais comparativas com anos anteriores, contas correntes de clientes e fornecedores, encomendas em aberto de clientes e fornecedores.

São ainda elaborados variados mapas (utilizando o *iReport*), no sentido de produzir relatórios fundamentais para a gestão e acompanhamento comercial da empresa.

3.3 Previsão de Vendas usando Redes Neurais

O sistema desenvolvido inclui uma funcionalidade adicional de relevante importância, que é um módulo de previsão de vendas mensais do cliente. Esta previsão é efectuada a partir de um histórico de vendas e de um conjunto de parâmetros bem definido (número de empregados da empresa, número de máquinas, stock no fim do mês anterior, valor de vendas no mesmo mês do ano anterior, produto interno bruto, taxa de desemprego e índice de preços no consumidor), utilizando redes neurais com o algoritmo “*Back-Propagation*”.

A figura seguinte apresenta a informação “on-line” presente no quadro de bordo comercial.

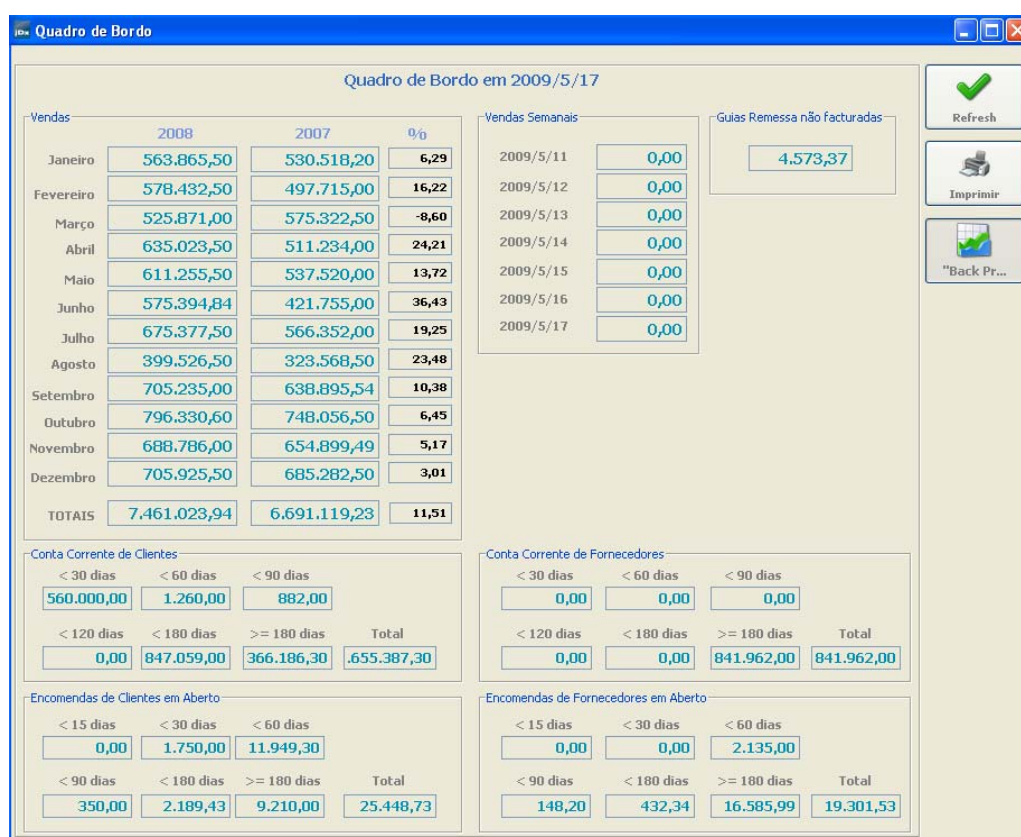


Figura 12: “Print Screen” da execução da classe “BrowserQuadroBordo” do projecto

Uma explicação sumária de como utilizar o método de aprendizagem de redes neurais através do algoritmo “*Back Propagation*” para prever as vendas mensais é apresentada nos parágrafos seguintes.

Vendas			
	2008	2007	%
Janeiro	563.865,50	530.518,20	6,29
Fevereiro	578.432,50	497.715,00	16,22
Março	525.871,00	575.322,50	-8,60
Abril	635.023,50	511.234,00	24,21
Mai	611.255,50	537.520,00	13,72
Junho	575.394,84	421.755,00	36,43
Julho	675.377,50	566.352,00	19,25
Agosto	399.526,50	323.568,50	23,48
Setembro	705.235,00	638.895,54	10,38
Outubro	796.330,60	748.056,50	6,45
Novembro	688.786,00	654.899,49	5,17
Dezembro	705.925,50	685.282,50	3,01
TOTAIS	7.461.023,94	6.691.119,23	11,51

Figura 13: “Print Screen” da execução da classe “BrowserQuadroBordo” do projecto (Vendas Mensais)

A formação da rede durante a fase de treino ou aprendizagem envolve três fases: a realimentação para formação das entradas padrão, a determinação do erro associado ao processo de “*back propagation*”, e a realização do ajuste dos pesos.

A rede neuronal é constituída por múltiplas camadas: a camada de entrada, as (uma ou mais) camadas escondidas e a camada de saída. Na rede considerada neste trabalho, existe apenas uma camada escondida. Cada uma das camadas possui várias unidades ou neurónios. As unidades entre duas camadas adjacentes estão todas interligadas, sendo que cada unidade da camada de entrada envia um sinal (peso da ligação) para cada unidade da camada escondida. Cada unidade da camada escondida soma os múltiplos sinais com diferentes pesos e, em seguida, aplica uma função de activação para gerar os sinais de saída dessa unidade, enviando-os para as unidades na camada de saída. As unidades da camada de saída recebem um sinal de cada unidade da camada escondida e calculam o resultado correspondente tendo em atenção os pesos dos sinais. O algoritmo escolhe aleatoriamente os pesos iniciais.

Na fase de treino da rede, é apresentado a esta um conjunto de exemplos (ou observações) com os quais a rede deve aprender. Para uma dada observação, é comparado o valor de cada unidade de saída calculada pela rede com o valor esperado para essa observação (erro).

Todas as observações são apresentadas à rede e os pesos são modificados de acordo com uma regra delta generalizada de modo a diminuir o valor do erro. Este processo de realimentação dos sinais e de propagação dos erros é repetido iterativamente até uma condição de paragem ser satisfeita. A paragem pode ser definida com um valor limiar do erro médio quadrático ou através de um valor máximo de iterações.

Especificação do Módulo Comercial ERP jDx

Depois da rede treinada e os seus pesos obtidos, podemos utilizar este algoritmo para efectuar a previsão.

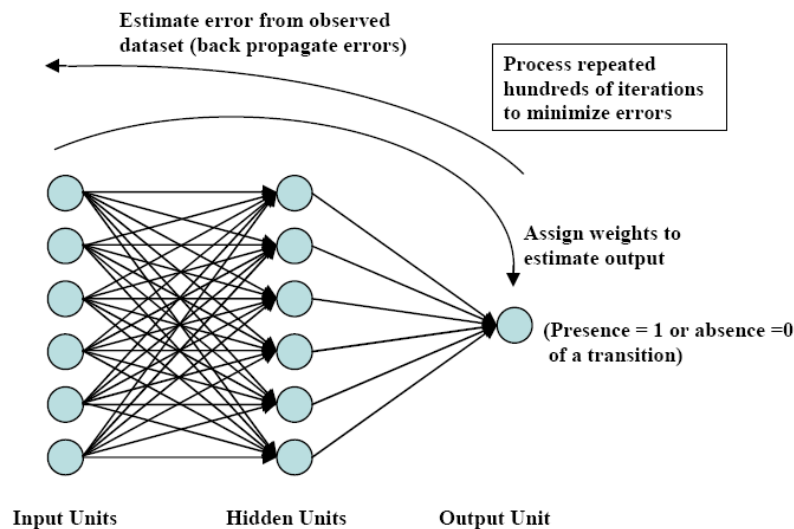


Figura 14: Arquitectura de uma rede neuronal "Back Propagation"

A empresa usada para a recolha das observações (exemplos) usadas na fase de aprendizagem da rede neuronal é uma conhecida PME metalomecânica nacional de fabrico de mobiliário metálico para escritório.

A selecção correcta dos parâmetros usados na aprendizagem da rede (valores da camada de entrada), são fundamentais para garantir a qualidade dos resultados de previsão da rede.

Após algumas semanas de uma certa indecisão nos parâmetros a escolher para a rede, foram seleccionados quatro parâmetros considerados fundamentais: o número de funcionários, o número de máquinas do *layout* fabril, o valor de vendas do mesmo mês do ano anterior e o valor em stock no final do mês anterior. A escolha destes parâmetros resulta de um conhecimento profundo da empresa em questão, na qual o autor presta serviços de consultoria desde 1998.

No sentido de efectuar testes comparativos que auxiliassem na determinação do melhor conjunto de parâmetros a considerar na previsão das vendas mensais, incluiu-se mais três outros parâmetros que foram sendo alternados nos diferentes testes: a evolução do produto interno bruto, a taxa de desemprego e o índice de preços no consumidor. Estes três valores tiveram como fonte o Instituto Nacional de Estatística.

A evolução de funcionários nesta empresa tem sido tendencialmente crescente até 2007, a partir daí têm-se mantido. A figura seguinte (Figura 15) apresenta a evolução mensal do número de funcionários da empresa para os meses compreendidos entre Janeiro de 2005 e Dezembro de 2008.




Figura 15: Parâmetro “nº de funcionários” de entrada da rede neuronal

A evolução do número de máquinas nesta empresa é absolutamente vital, sempre foi uma empresa que apostou em tecnologia, tendo o número total de máquina no *lay-out* fabril crescido até aos dias de hoje. A figura seguinte representa a evolução mensal de máquinas de Janeiro de 2005 a Dezembro de 2008 (24x2 meses)




Figura 16: Parâmetro “nº de máquinas” de entrada da rede neuronal

O valor das vendas mensais anteriores (do mesmo mês do ano anterior) é um bom parâmetro de aprendizagem, uma vez que esse histórico evidencia bem a sazonalidade das vendas (por exemplo, desde que a empresa foi constituída, o mês de Agosto sempre foi o mais fraco em termo de vendas). Da mesma forma o último trimestre de cada ano costuma ser um

Especificação do Módulo Comercial ERP jDx

bom período de vendas para a empresa. A figura seguinte representa a evolução mensal de vendas de Janeiro de 2005 a Dezembro de 2008 (48 meses)

...




Figura 17: Parâmetro valor de vendas no mesmo mês do ano anterior

A evolução mensal de stock de produto acabado é o parâmetro que mais varia ao longo do tempo, pois depende das vendas e das compras entre outros factores. Numa altura em que os mercados se encontram um pouco estagnados em termos de vendas, é de difícil previsão a sua evolução. A figura seguinte representa a evolução do stock mensal de mercadoria entre Janeiro de 2005 a Dezembro de 2009 (60 meses)




Figura 18: Parâmetro “Evolução Mensal de Stock” de entrada da rede neuronal

Como já foi referido, estes foram os quatro primeiros parâmetros seleccionados como base.

Foram seleccionados de seguida mais três parâmetros adicionais: produto interno bruto, taxa de desemprego e índice de preços no consumidor, que são mais de conjectura da economia e por consequência de mercado onde a empresa está inserida.

O Produto Interno Bruto (**PIB**) representa a soma (em valores monetários) de todos os bens e serviços finais produzidos numa determinada região, durante um período determinado (mês, trimestre, ano, etc.). O PIB é um dos indicadores mais utilizados na macro economia, com o objectivo de medir a actividade económica de uma região. A figura seguinte representa a evolução do PIB entre Janeiro de 2005 e Dezembro de 2008.




Figura 19: Parâmetro “Evolução do P.I.B.” de entrada da rede neuronal (Fonte I.N.E.)

Na economia, **taxa de desemprego** representa a percentagem de pessoas capazes de exercer uma profissão e que procuram um emprego remunerado, mas que, por diversas razões, não entram no mercado de trabalho. Também podem estar incluídos na taxa de desemprego, aqueles que exercem trabalhos não remunerados. A taxa de desemprego é o número dos trabalhadores desempregados dividido pela força de trabalho total. A figura seguinte representa a evolução da taxa de desemprego entre Janeiro de 2005 e Dezembro de 2008.




Figura 20: Parâmetro “Evolução da Taxa de Desemprego” de entrada da rede neuronal (Fonte I.N.E.)

O Índice de Preços no Consumidor (IPC) considera a variação dos preços, calculado mensalmente, e que toma por base os gastos das famílias. A figura seguinte representa a evolução do índice de preços no consumidor entre Janeiro de 2005 e Dezembro de 2008.




Figura 21: Parâmetro “Evolução de Preços no Consumidor” de entrada da rede neuronal (Fonte I.N.E.)

3.4 *Resumo e Conclusões*

A principal dificuldade sentida no desenvolvimento do módulo comercial do ERP foi a consolidação de conhecimento sobre toda a tecnologia envolvida.

Os requisitos do módulo comercial eram bem conhecidos à partida, as necessidades presentes e futuras dos clientes relativas ao software estavam também dominadas.

No entanto foi um enorme desafio tirar partido destas tecnologias, adaptando-as aos requisitos do módulo comercial.

4 Implementação

O módulo comercial desenvolvido implementa requisitos funcionais e não funcionais.

Entre os requisitos funcionais enumeram-se:

- a modelação do estado interno persistente e partilhado do sistema
- a estrutura de documentos trocados entre o sistema e o ambiente
- a modelação de tipos de dados



Figura 22 Relacionamento entre as tabelas de documentos comerciais do módulo comercial do projecto jDx

Na figura 22 está presente o relacionamento entre a tabela de cabeçalho e a tabela de linhas dos documentos comerciais. Está ainda presente a *view* das duas tabelas, que nos permite o acesso aos dados das duas tabelas em simultâneo quando necessário. Os *triggers* utilizados em cada uma das tabelas para actualização de campos em automático também são referidos na figura 22.

Os requisitos suplementares, também conhecidos por requisitos não funcionais, apresentam-se como um complemento aos requisitos funcionais e têm que ver principalmente com questões como tempos de resposta, segurança, fiabilidade, normas, entre outros. Estes

Implementação

requisitos assumem, por vezes, maior relevância que os requisitos funcionais uma vez que os podem inviabilizar, tornando o sistema obsoleto.

Os parágrafos seguintes enumeram alguns dos requisitos não funcionais considerados relevantes neste projecto.

Usabilidade

Descrição: A interface do software procurará ser o mais intuitiva possível. Deverão ser usadas interfaces simples, comuns e de fácil interpretação e aprendizagem para os utilizadores. O percurso do utilizador deverá ser acompanhado com tópicos de ajuda e mensagens de erro claras e esclarecedoras. A facilidade de configuração do sistema deverá ser também uma aposta tendo em vista esta adaptação ao utilizador.

Prioridade: Essencial

Utilidade

Descrição: Sendo o objectivo máximo deste módulo a geração de documentação, esta deverá apresentar-se como uma mais valia a soluções já existentes. Assim este deverá ser um ponto a privilegiar, permitindo a criação de documentação realmente fácil de criar, ler, pesquisar e editar, apresentando boa estruturação, consistência e modularidade.

Prioridade: Essencial

Eficiência

Descrição: O sistema deverá ter um tempo de resposta reduzido às acções realizadas pelo utilizador. Sabendo que o software irá ser desenvolvido em java, a qualidade do código produzido será preponderante para acelerar as tarefas. Outro factor decisivo para atingir este objectivo será a eficiência do repositório visto que os acessos ao mesmo são bastante frequentes.

Prioridade: Desejável

Fiabilidade

Descrição: A robustez do software deverá ser o mais apurada possível, evitando perdas ou corrupção da informação.

Prioridade: Essencial

Manutenção

Descrição: O sistema deverá ser concebido de maneira a permitir uma fácil manutenção e alteração das funcionalidades que o constituem, bem como a introdução de novas funcionalidades.

Prioridade: Desejável

Portabilidade

Descrição: O sistema deve ser o mais portátil possível, e deverá ser, pelo menos, compatível com os diversos sistemas operativos que o JVM actualmente suporta.

Prioridade: Desejável

Implementação

Ao nível das interfaces com o utilizador o sistema fornecerá ao utilizador um ambiente de interacção bastante intuitiva. O IDE *JBuilder* fornecerá as ferramentas de trabalho que possibilitarão a criação de máscaras com um bom nível *UserFriendly* que servirão como meio para o utilizador inserir informação no repositório e posteriormente a poder explorar. No que diz respeito à GUI (*Graphical User Interface*), esta será simples.

Os utilizadores finais do produto são aqueles que lidam com sistemas de *software* nas suas diversas fases de desenvolvimento. Tendo em conta que o ERP é uma ferramenta que vai ser utilizada desde o colaborador de armazém até ao responsável pela empresa, vemos que os utilizadores são bastante heterogéneos a todos os níveis, quer em termos de conhecimentos informáticos, quer em termos de conhecimento sobre a instituição, quer ainda em termos de formação geral. Razão pela qual se deve ter em atenção no desenvolvimento das máscaras de interface com os utilizadores o *utilizador potencial*, de forma a maximizar a sua adaptabilidade.

4.1 A implementação do Módulo Comercial

A definição de uma correcta e adequada estrutura lógica de alto nível para a criação de *software* é determinante para o sucesso e longevidade do produto.

No entanto, como em qualquer sistema, o desempenho e a velocidade estão relacionados com a quantidade de subsistemas utilizados. Isto é, mais subsistemas implicam mais interfaces, logo existe grande probabilidade de obter menor velocidade usando muitos subsistemas. É ainda verdade que mais subsistemas implicam em princípio mais “peças” de software pelo que a probabilidade de colapso do conjunto parece também aumentar. Sabemos que isto não é consensual mas é a opinião do autor.

Mas o cálculo probabilístico também não ajuda a alterar esta opinião, pois por exemplo, partindo do princípio que para que exista sucesso num voo seja necessário chegar ao destino com metade dos motores em funcionamento (apenas se considera esta condição nesta modelização simplista) prova-se que para uma dada gama de valores de probabilidade de falha de um motor, um bimotor é mais seguro que um quadrimotor. Não existe nenhum trauma quanto ao uso de sistemas distribuídos, mas na prática evitamos um pouco essa arquitectura.

Por outro lado a existência de mais subsistemas implica mais trabalho a todos os níveis para os responsáveis pelo projecto. E se o número destes últimos for manifestamente escasso (que é o que acontece na empresa em questão) quando comparado com o número de subsistemas em que se tem de actuar, existe também uma clara degradação na produtividade do ser humano.

É no entanto verdade que se eventualmente se pretender trocar o *PostgreSQL* por outro SGBD, essa permuta seria muito mais fácil de efectuar se o projecto tivesse sido desenvolvido usando 3 camadas (Interface, Lógica de Negócios e Acesso a Dados) resultantes da adaptação do modelo MVC (*Model, View, Controller*). Contudo, o trabalho de desenvolvimento para manter esse modelo seria também maior.

Para finalizar falta tocarmos no aspecto comercial, não é fácil no nosso cliente tipo, e note-se que não são micro empresas com fabrico, falar num Servidor Web ou Ficheiros + Servidor para a Camada Lógica de Negócio + Servidor PostgreSQL, mesmo que fisicamente juntássemos

Implementação

os Servidores de Ficheiros com o Servidor PostgreSQL, continuaria a não ser fácil "vender" esta solução.

Esta abordagem comercial iria "abrir" na melhor das hipóteses um dossier comercial longo. Mas é tarefa dos técnicos continuar a apoiar os clientes na busca das melhores decisões e técnicas economicamente viáveis, tarefa que se revela por vezes bastante custosa.

Foi esta panóplia de princípios que nos levaram a optar por uma arquitectura composta por duas camadas: Interface e Acesso aos Dados.

4.1.1 Arquitectura lógica

Uma perspectiva geral da decomposição horizontal e vertical do módulo comercial do jDx é apresentada na figura seguinte (Figura 23):

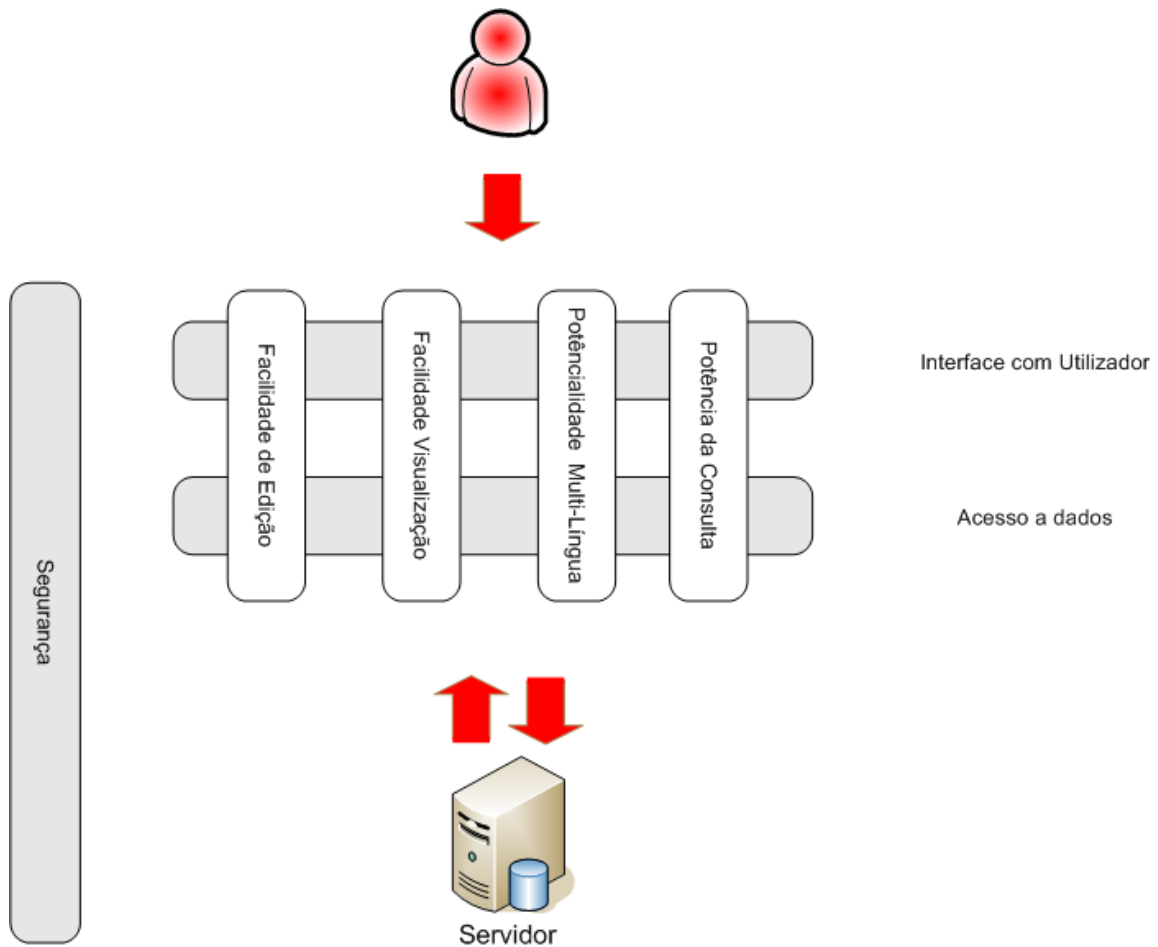


Figura 23: Arquitectura lógica do módulo comercial do jDx

A definição de uma arquitectura horizontal pode condicionar decisivamente a qualidade de um produto de *software*. Vários problemas podem ocorrer se uma aplicação misturar código de acesso a dados, lógica de negócio e apresentação, sendo que, estes tipos de aplicações são normalmente difíceis de manter devido à interdependência entre componentes. Actualmente, no desenvolvimento de interfaces, e mesmo de aplicações completas, um dos modelos mais utilizados é o MVC. No entanto neste projecto optou-se por uma divisão em 2 camadas (como já foi referido). Esta opção resultou também da utilização da ferramenta JBuilder (que convém

Implementação

referir não foi uma decisão unilateral dos projectistas). A utilização das classes e ferramentas específicas da Borland existentes em JBuilder para trabalhar a interface gráfica com o utilizador conduziram a esta arquitectura de 2 camadas.

Na implementação do jDx procurou-se encontrar para cada camada a tecnologia que melhor se adequasse aos objectivos em vista. Claro que existiu uma tecnologia que se apresentou transversal a praticamente todos os módulos, que foi o JBuilder que é usado essencialmente na camada de apresentação. Na camada de acesso aos dados, é utilizado o iReport para o acesso aos dados e o SGBD PostgreSQL para o armazenamento/gestão desses mesmos dados.

Concretizando e pormenorizando, uma perspectiva geral do jDx é ilustrada no seguinte esquema (figura 24):

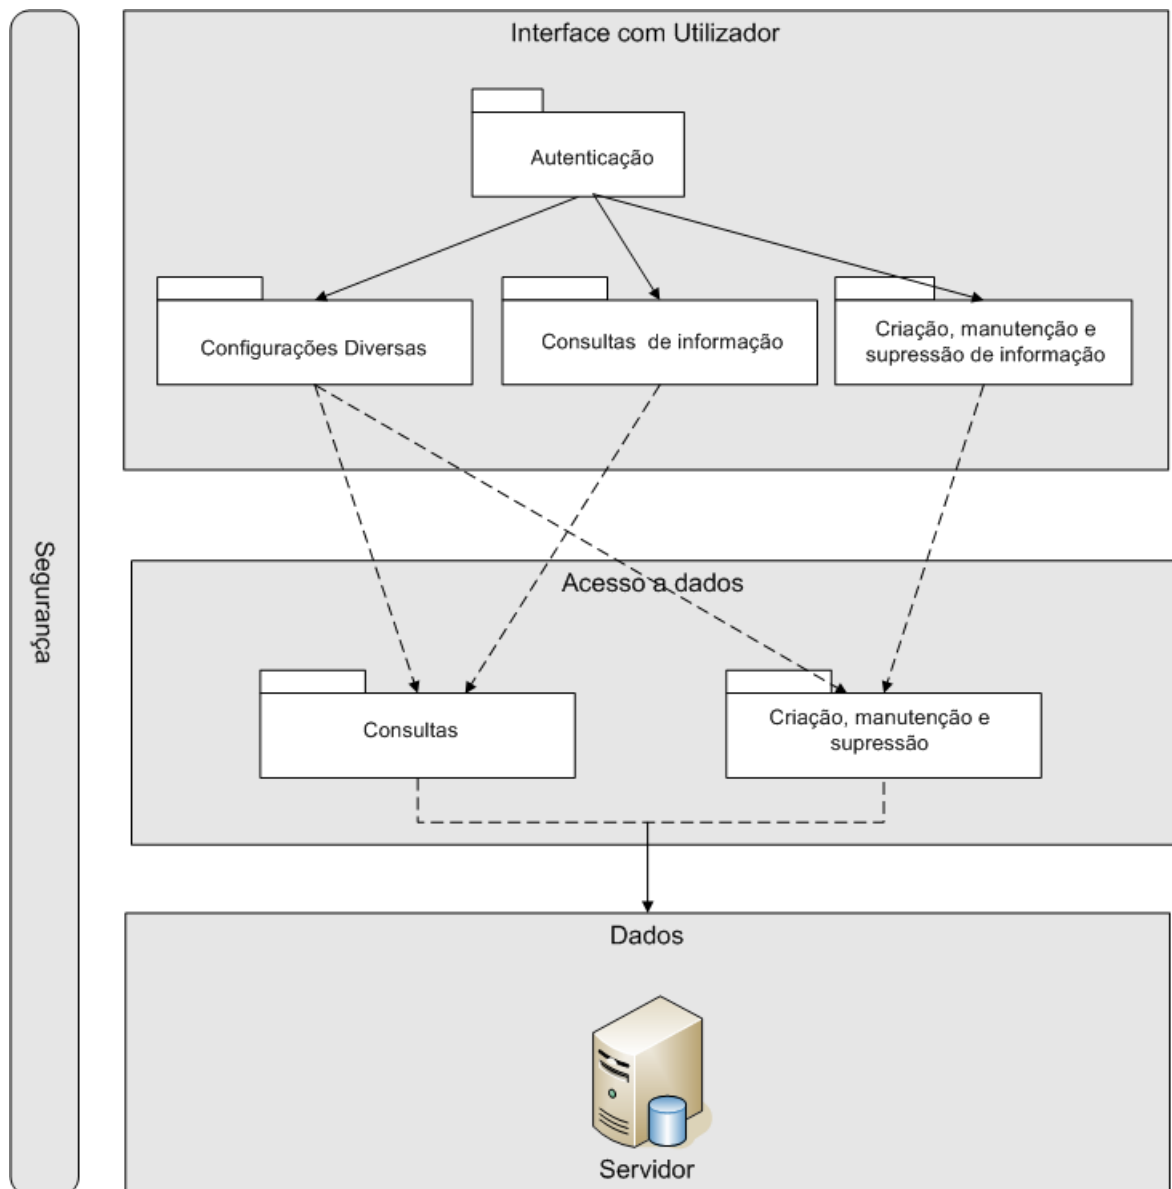


Figura 24: Perspectiva geral do jDx

No módulo comercial do jDx foram consideradas as seguintes funcionalidades (Figura 25):

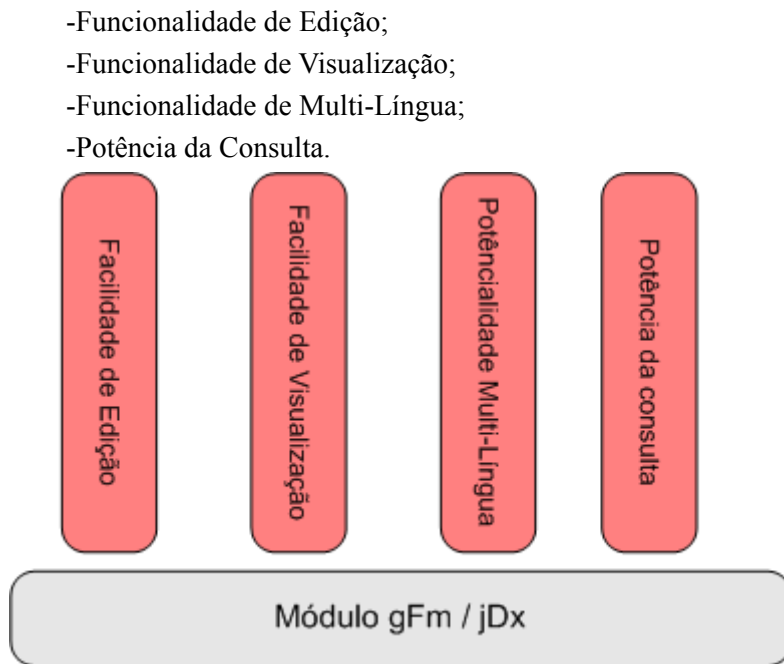


Figura 25: Algumas funcionalidades do módulo comercial jDx

4.1.2 Arquitetura física

4.1.2.1 Modelo

O sistema a desenvolver trata-se de um sistema distribuído em que existe um servidor, o repositório, que fornecerá e receberá dados de diversos clientes. Assim, estamos perante uma arquitetura física segundo o modelo cliente-servidor (Figura 26).

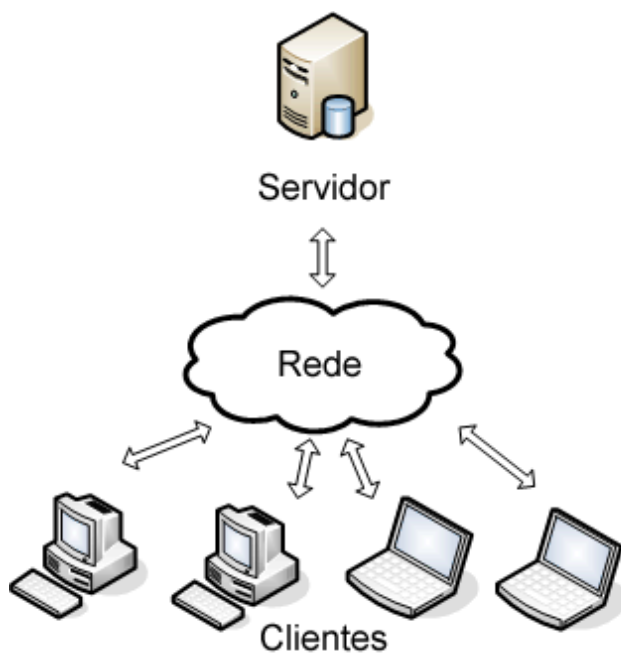


Figura 26: Modelo de Arquitectura física do jDx

4.1.2.2 Arquitectura

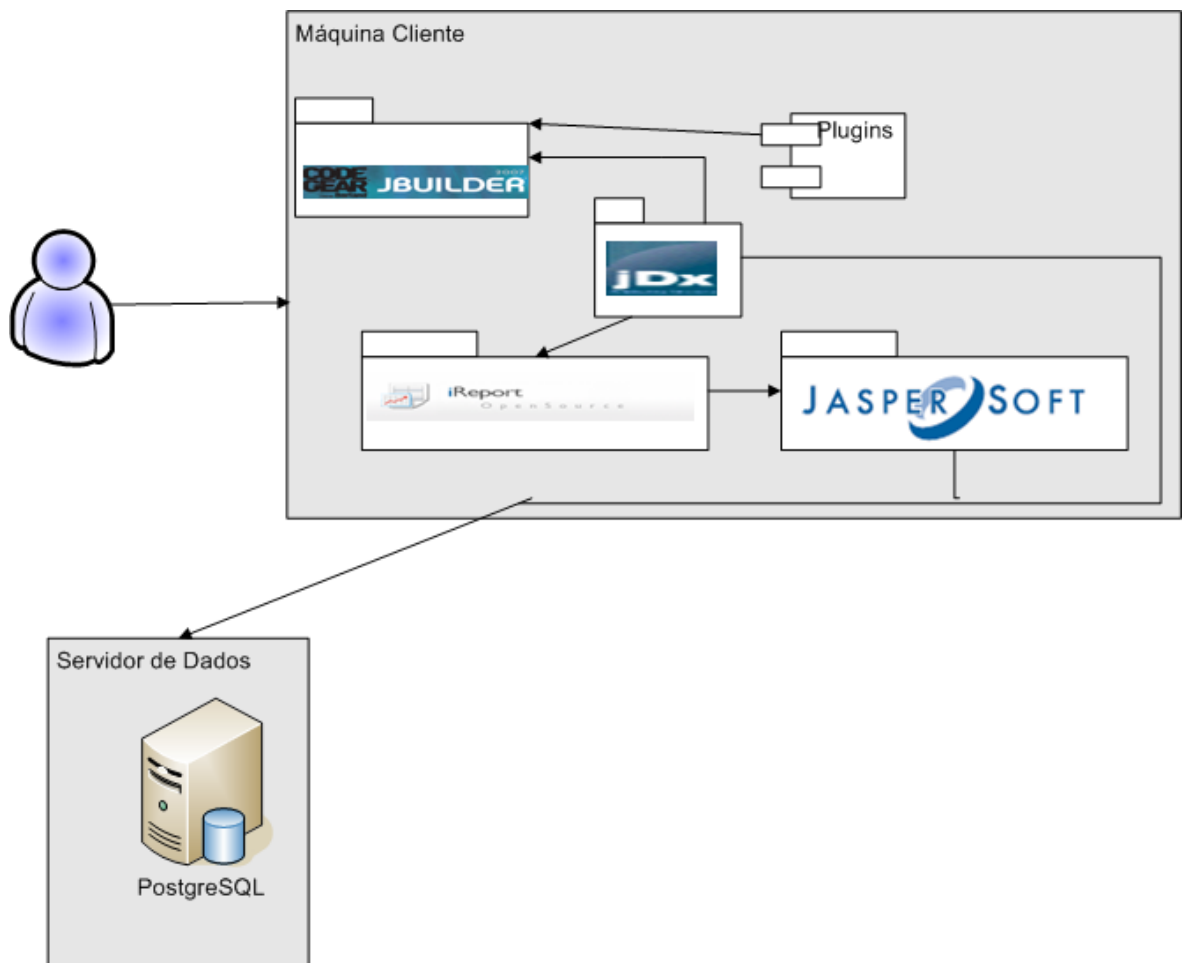


Figura 27: Arquitectura do jDx

A figura 27 identifica a arquitectura presente em todo o ERP jDx, são identificadas as ferramentas mais utilizadas no desenvolvimento do módulo comercial e o seu interface com os utilizadores e o servidor de dados.

O acesso à informação produzida pelo **jDx**, possibilita as seguintes funcionalidades:

- Funcionalidades de autenticação;
- Restantes requisitos funcionais.

4.1.2.4 Servidor de dados

Trata-se de um servidor de dados, utiliza o SGBD *PostgreSql*.

4.1.3 Principais decisões de projecto do jDx

Implementação

O desenvolvimento de aplicações apresenta-se maioritariamente como um processo bastante repetitivo. Assim torna-se importante definir um conjunto de características gerais que se verificam nos diversos aspectos da aplicação. O conjunto destas decisões deverá permitir agilizar o processo de integração de diversas funcionalidades de um mesmo módulo e inclusivamente com módulos externos, como acontece no projecto global (ERP) que se pretende desenvolver.

No tocante ao módulo comercial do jDx as principais decisões de projecto foram:

- 1 - Independência do idioma: Neste momento o que está projectado e implementado é ser automaticamente escolhido o idioma a utilizar pela aplicação, em função da autenticação efectuada.
- 2 - Impressão/Visualização: Garantir que tudo o que é passível de ser impresso seja também visualizável no ecrã. Esta pode parecer uma decisão estranha, mas trata-se de uma luta antiga, pois ainda hoje muitos dos utilizadores típicos arranjam todos os pretextos e mais algum para imprimir sem haver necessidade de tal.
- 3 - Erros: Actualmente a linguagem de desenvolvimento adoptada, o Java, tal como muitas outras linguagens orientadas a objectos, permitem o tratamento de erros através do uso de excepções. Assim, este será maioritariamente o mecanismo de processamento de erros do sistema. A forma de apresentação destes erros ao utilizador será, maioritariamente, através do recurso a janelas de diálogo especialmente concebidas para o efeito e disponibilizadas pela plataforma de desenvolvimento. As mensagens serão adequadas o mais possível às situações, fornecendo ao utilizador uma clara ideia do tipo de erro que acabou de surgir e, eventualmente, de como o corrigir.

4.1.4 As tecnologias

As tecnologias escolhidas poderão condicionar totalmente a qualidade e o tempo de desenvolvimento do produto de *software* a desenvolver. Assim uma boa escolha das mesmas será de bastante importância e assume um carácter decisivo. As principais tecnologias a ser utilizadas neste projecto são as seguintes:

4.1.4.1 Java

A escolha da linguagem Java foi fundamentalmente determinada pela possibilidade de procura de robustez empírica.

A linguagem Java é uma linguagem orientada a objectos, desenvolvida para ser compilada para *bytecode's*, interpretados em *runtime*. É uma linguagem proprietária, mas apesar disso a Sun (sua titular), disponibiliza a maioria das suas implementações livres de custo.

4.1.4.2 JBuilder

Embora isso já tivesse sido referido, a decisão de utilizar o JBuilder foi tomada pela empresa Dinâmica em Janeiro de 2005, essencialmente porque pesquisando a informação disponível à data e recorrendo à colaboração de pessoas de reconhecido mérito na área da

Implementação

informática, se chegou à conclusão que esta seria a melhor solução para cumprir os 2 grandes objectivos da empresa:

-desenvolver uma aplicação independente (o mais possível) da plataforma - o sistema operativo.

-arranjar uma ferramenta que permitisse otimizar a interface gráfica com o utilizador pois era a maior lacuna na altura.

4.1.4.3 PostgreSQL

PostgreSQL é o Sistema de Gestão de Bases de Dados (SGBD) objecto-relacional, *open source*, realmente gratuito mas não deixando de ser por isso uma solução fiável ao nível das aplicações Industriais e Comerciais.

De entre as funcionalidades disponíveis do PostgreSQL, são de realçar as seguintes:

- Execução de funções no código do próprio servidor, escritas em diversas linguagens, realcem-se as seguintes:
- PL/pgSQL, linguagem nativa do postgresSQL;
- C/C++ ou Java;
- Definição de *triggers* sobre tabelas;
- Gestão de acessos concorrentes;
- Variadíssimos tipos de dados;
- Criação de objectos definidos pelo utilizador;
- Herança de atributos duma tabela pai, para uma tabela filha;
- Transacções;

Foram essencialmente os aspectos de gratuitidade e fiabilidade aliado a já estar no mercado há muito tempo e com boas indicações em fóruns que estiveram na base da nossa escolha.

4.1.4.4 Jasper Report

É no fundo o motor que faz a ligação do iReport ao PostgreSQL. Na sua classe e em termos de *free software* pareceu-nos a melhor opção.

4.1.4.5 iReport

É um editor de formulários, gratuito que trabalha muito bem com o Jasper Report. Logo após a escolha do Jasper Report a do iReport é de alguma forma natural.

4.2 A implementação do Quadro de Bordo

O Quadro de Bordo é a síntese de informação considerada útil para a gestão de uma empresa. Compara as vendas mensais do ano em curso com as do ano anterior. Auxilia em termos financeiro no sentido de agrupar por idades as contas correntes de clientes e de fornecedores. Contém ainda informação das encomendas de clientes e fornecedores em aberto (também por idades).

Implementação

A selecção da classe Quadro de Bordo para exemplificar a implementação parece importante uma vez que serve de teste para muitas classes que vão sendo desenvolvidas no ERP jDx, tais como classes do módulo financeiro, módulo de logística e módulo comercial.

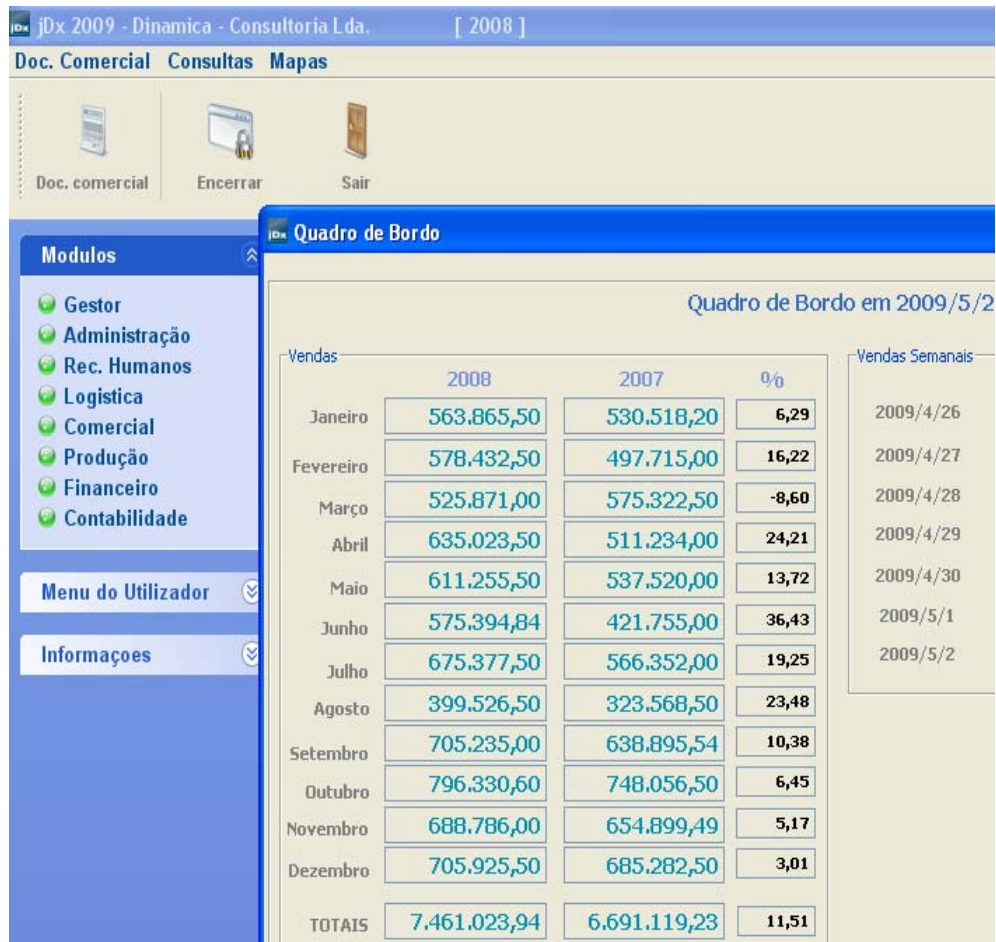


Figura 28: A chamada da classe “BrowserQuadroBordo”

Como qualquer classe desenvolvida ou a desenvolver no ERP jDx, esta classe é multi-idioma, situação que é controlada pelo utilizador.

4.3 Previsão de Vendas

O módulo correspondente à previsão do volume de vendas mensais do cliente constitui uma funcionalidade importante neste projecto. A previsão é efectuada através de uma rede neuronal.

Para a realização de testes comparativos, foram efectuadas duas análises. Numa primeira análise foram utilizados 48 meses de histórico (2004 a 2007), na aprendizagem da rede, para prever as vendas mensais de 2008. Numa segunda análise foram utilizados 60 meses de histórico (2004 a 2008), na aprendizagem da rede, para prever as vendas dos 5 primeiros meses de 2009 (as conhecidas até ao momento).

Relativamente à estrutura da rede neuronal, a camada de entrada da rede possui 4 unidades, a camada intermédia 3, e a camada de saída naturalmente 1 unidade.

Implementação

Em cada um dos testes variou-se com incrementos decimais o parâmetro “*learning rate*” entre 0.5 e 0.8 e o parâmetro *momentum* entre 0.1 e 0.4.

Quanto mais alto o valor do parâmetro “*learning rate*” mais rapidamente a rede aprende. Já o *momentum* evita oscilações da rede na aprendizagem, evitando mínimos locais.

Inicialmente foram efectuados alguns testes com mais de 4 parâmetros de entrada, mas os resultados não foram nada animadores em virtude do histórico conhecido não ser suficiente para produzir resultados satisfatórios.

Análise 1

Nesta análise foram utilizados 48 meses de histórico (2004 a 2007), na aprendizagem da rede, para prever as vendas mensais de 2008.

Dos parâmetros seleccionados para teste, foram escolhidos inicialmente os 4 seguintes: nº de funcionários (NF), Produto Interno Bruto (PIB), Índice de Preços no Consumidor (IPC) e Taxa de Desemprego (TD). Os resultados obtidos são apresentados na tabela seguinte (Tabela 1):

Implementação

Previsões Vendas Mensais Ano 2008 - 4 Parâmetros - Back Pro							
<small>(Nº de Funcionários / PIB / IPC / Taxa de Desemprego)</small>							
<small>Nº de iterações de aprendizagem da rede = 500000</small>							
<small>Nº Elementos do Conjunto de Treino = 48</small>							
<small>Nº Elementos do Conjunto de Teste = 12</small>							
		Learning Rate	0,5	0,6	0,7	0,8	
		Momentum					
	0,1						
ERRO MÉDIO	0,2		34,083	33,417	24,833	56,417	Mínimo
ABSOLUTO	0,3		55,417	34,667	27,667	80,083	24,833 Média
(milhares de euros)	0,4		51,000	60,917	84,167	76,750	Máximo 66,479
			125,083	88,583	129,500	101,083	129,500
		Learning Rate	0,5	0,6	0,7	0,8	
		Momentum					
	0,1		7,718	6,817	4,855	13,078	Mínimo
ERRO MÉDIO	0,2		12,367	6,898	6,814	15,820	4,855 Média
(%)	0,3		10,360	14,246	16,729	15,686	Máximo 13,765
	0,4		23,890	19,383	24,883	20,699	24,883
		Learning Rate	0,5	0,6	0,7	0,8	
		Momentum					
	0,1		89,000	75,000	60,000	116,000	Mínimo
ERRO MÁXIMO	0,2		103,000	99,000	58,000	251,000	58,000 Média
ABSOLUTO	0,3		98,000	173,000	169,000	149,000	Máximo 184,875
(milhares de euros)	0,4		425,000	403,000	475,000	215,000	475,000
		Learning Rate	0,5	0,6	0,7	0,8	
		Momentum					
	0,1		25,806	18,564	14,851	44,624	Mínimo
ERRO MÁXIMO	0,2		32,796	16,751	29,570	40,354	14,851 Média
(%)	0,3		20,675	55,376	30,952	27,957	Máximo 40,611
	0,4		81,107	73,810	100,211	36,379	100,211
		Learning Rate	0,5	0,6	0,7	0,8	
		Momentum					
	0,1		0,00374	0,00366	0,00366	0,00318	Mínimo
ERRO MÉDIO	0,2		0,00307	0,00490	0,00333	0,00451	0,00248 Média
QUADRÁTICO	0,3		0,00248	0,00248	0,00394	0,00516	Máximo 0,00369
	0,4		0,00326	0,00460	0,00250	0,00459	0,00516

Tabela 1: Resumo dos resultados obtidos em Análise 1 (parâmetros: NF/PIB/IPC/TD)

A figura 29 e a figura 30 representam, respectivamente, o gráfico com o menor e o maior erro médio absoluto obtido na fase de teste da rede neuronal (previsão das vendas mensais entre Janeiro de 2008 e Dezembro de 2008):

Implementação




Figura 29: Menor erro médio absoluto em Análise 1 (parâmetros NF/PIB/PIC/TD)




Figura 30: Maior erro médio absoluto em Análise 1 (parâmetros NF/PIB/PIC/TD)

Implementação

De seguida foram ensaiados como parâmetros de entrada os seguintes: número de funcionários (NF), número de máquinas (NM), volume de vendas do mesmo mês do ano anterior (V) e Índice de Preços no Consumidor (IPC). Os resultados obtidos são apresentados na tabela 2.

Previsões Vendas Mensais Ano 2008 - 4 Parâmetros - Back Propa								
<small>(Nº de Funcionários / Nº de Máquinas / Vendas do mesmo mês do Ano Anterior / I.P.C.)</small>								
<small>Nº de iterações de aprendizagem da rede = 500000</small>								
<small>Nº Elementos do Conjunto de Treino = 48</small>								
<small>Nº Elementos do Conjunto de Teste = 12</small>								
		Learning Rate	0,5	0,6	0,7	0,8		
	Momentum							
	0,1		43,750	62,667	42,500	43,917	Mínimo	
ERRO MÉDIO	0,2		41,167	67,083	54,583	88,167	26,083	Média
ABSOLUTO	0,3		88,000	70,250	172,417	53,167	Máximo	61,172
(milhares de euros)	0,4		26,083	36,917	49,917	38,167	172,417	
		Learning Rate	0,5	0,6	0,7	0,8		
	Momentum							
	0,1		9,500	10,894	10,826	10,812	Mínimo	
ERRO MÉDIO	0,2		9,892	12,483	18,158	23,499	5,924	Média
(%)	0,3		18,121	14,047	40,067	11,553	Máximo	13,796
	0,4		5,924	7,073	10,904	6,978	40,067	
		Learning Rate	0,5	0,6	0,7	0,8		
	Momentum							
	0,1		144,000	370,000	144,000	204,000	Mínimo	
ERRO MÁXIMO	0,2		88,000	349,000	254,000	358,000	57,000	Média
ABSOLUTO	0,3		247,000	142,000	479,000	175,000	Máximo	216,125
(milhares de euros)	0,4		57,000	108,000	104,000	235,000	479,000	
		Learning Rate	0,5	0,6	0,7	0,8		
	Momentum							
	0,1		29,570	62,606	39,785	50,495	Mínimo	
ERRO MÁXIMO	0,2		36,022	59,052	124,731	136,022	17,574	Média
(%)	0,3		39,711	27,099	173,118	30,645	Máximo	57,363
	0,4		19,355	17,574	32,258	39,763	173,118	
		Learning Rate	0,5	0,6	0,7	0,8		
	Momentum							
	0,1		0,00203	0,00203	0,00282	0,00183	Mínimo	
ERRO MÉDIO	0,2		0,00180	0,00180	0,00174	0,00250	0,00146	Média
QUADRÁTICO	0,3		0,00146	0,00177	0,00318	0,00318	Máximo	0,00220
	0,4		0,00229	0,00263	0,00162	0,00247	0,00318	

Tabela 2: Resumo dos resultados obtidos em Análise 1 (parâmetros NF/NM/V/IPC)

As figuras 31 e 32 apresentam, respectivamente, o gráfico com o menor e o maior erro médio absoluto obtido na fase de teste da rede neuronal:

Implementação




Figura 31: Menor erro médio absoluto em Análise 1 (parâmetros NF/NM/V/IPC)




Figura 32: Maior erro médio absoluto em Análise 1 (parâmetros NF/NM/V/IPC)

Implementação

De seguida foram ensaiados como parâmetros de entrada o número de funcionários (NF), o número de máquinas (NM), o volume de vendas do mesmo mês do ano anterior (V) e o Produto Interno Bruto (PIB). Os resultados obtidos são apresentados na tabela seguinte (tabela 3):

Previsões Vendas Mensais Ano 2008 - 4 Parâmetros - Back Propa							
<small>(Nº de Funcionários / Nº de Máquinas / Vendas do mesmo mês do Ano Anterior / P.I.B.)</small>							
<small>Nº de iterações de aprendizagem da rede = 500000</small>							
<small>Nº Elementos do Conjunto de Treino = 48</small>							
<small>Nº Elementos do Conjunto de Teste = 12</small>							
		Learning Rate	0,5	0,6	0,7	0,8	
	Momentum						
	0,1		56,417	15,500	64,167	61,167	Mínimo
ERRO MÉDIO	0,2		81,583	70,750	73,500	50,167	15,500 Média
ABSOLUTO	0,3		87,000	105,500	85,750	61,083	Máximo 66,891
(milhares de euros)	0,4		48,083	66,333	62,833	80,417	105,500
		Learning Rate	0,5	0,6	0,7	0,8	
	Momentum						
	0,1		10,485	2,884	14,138	12,795	Mínimo
ERRO MÉDIO	0,2		14,347	13,437	14,522	9,463	2,884 Média
(%)	0,3		16,419	18,147	24,521	12,299	Máximo 13,846
	0,4		10,873	12,959	12,662	21,579	24,521
		Learning Rate	0,5	0,6	0,7	0,8	
	Momentum						
	0,1		131,000	51,000	288,000	165,000	Mínimo
ERRO MÁXIMO	0,2		315,000	176,000	180,000	345,000	51,000 Média
ABSOLUTO	0,3		414,000	298,000	358,000	142,000	Máximo 216,875
(milhares de euros)	0,4		90,000	158,000	155,000	204,000	414,000
		Learning Rate	0,5	0,6	0,7	0,8	
	Momentum						
	0,1		23,020	9,341	48,731	30,108	Mínimo
ERRO MÁXIMO	0,2		50,643	27,981	32,061	58,376	9,341 Média
(%)	0,3		87,342	50,423	156,452	28,218	Máximo 50,726
	0,4		28,495	32,377	38,366	109,677	156,452
		Learning Rate	0,5	0,6	0,7	0,8	
	Momentum						
	0,1		0,00306	0,00306	0,00144	0,00266	Mínimo
ERRO MÉDIO	0,2		0,00173	0,00303	0,00354	0,00135	0,00135 Média
QUADRÁTICO	0,3		0,00181	0,00192	0,00258	0,00381	Máximo 0,00264
	0,4		0,00269	0,00341	0,00325	0,00293	0,00381

Tabela 3: Resumo dos resultados obtidos em Análise 1 (parâmetros NF/NM/V/PIB)

As figuras 33 e 34 apresentam, respectivamente, o gráfico com o menor e o maior erro médio absoluto obtido na fase de teste da rede neuronal:

Implementação

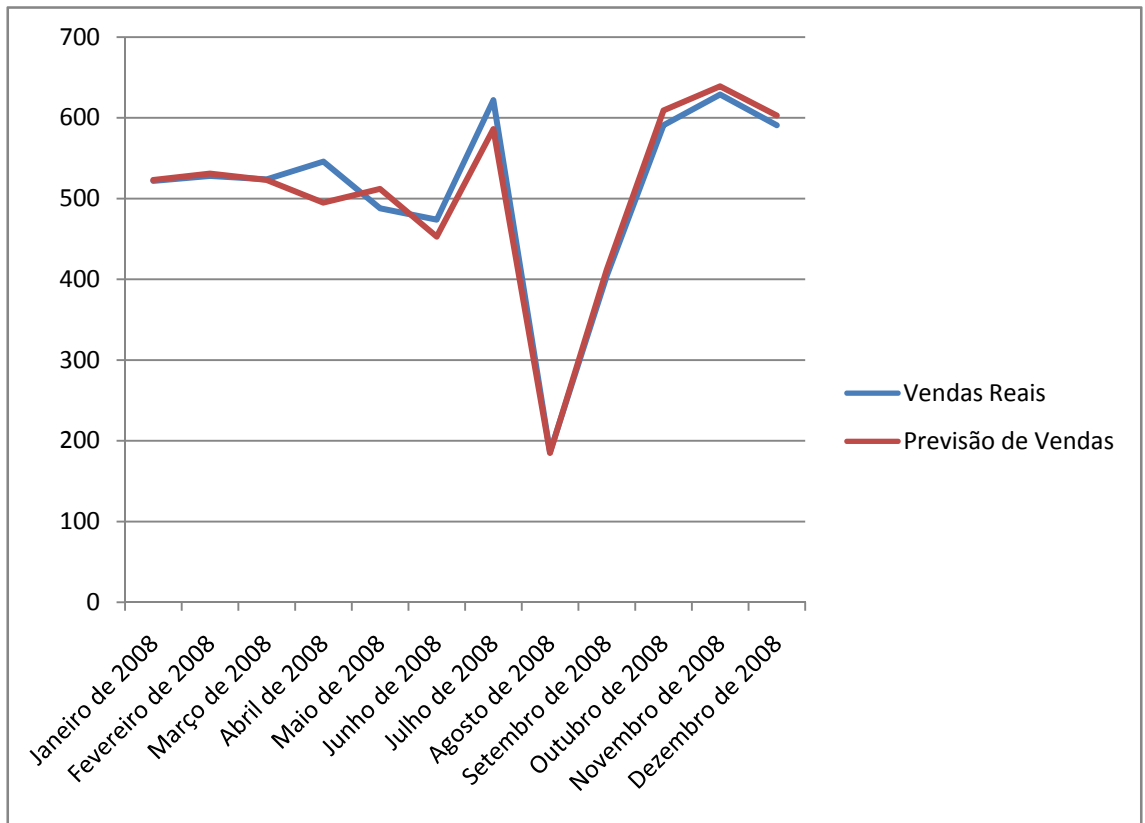


Figura 33: Menor erro médio absoluto em Análise 1 (parâmetros NF/NM/V/PIB)




Figura 34: Maior erro médio absoluto em Análise 1 (parâmetros NF/NM/V/PIB)

Implementação

Em seguida foram ensaiados como parâmetros de entrada: o número de funcionários (NF), o número de máquinas (NM), o volume de vendas do mesmo mês do ano anterior (V) e o valor do stock do mês anterior (S). A tabela seguinte (tabela X) apresenta os resultados obtidos:

Previsões Vendas Mensais Ano 2008 - 4 Parâmetros - Back Propa							
<small>(Nº de Funcionários / Nº de Máquinas / Vendas do mesmo mês do Ano Anterior / Stock Fim do Mês Anterior)</small>							
<small>Nº de iterações de aprendizagem da rede = 500000</small>							
<small>Nº Elementos do Conjunto de Treino = 48</small>							
<small>Nº Elementos do Conjunto de Teste = 12</small>							
		Learning Rate	0,5	0,6	0,7	0,8	
	Momentum						
	0,1		72,833	62,917	58,750	66,083	Mínimo
ERRO MÉDIO	0,2		89,083	58,500	24,500	36,583	24,500 Média
ABSOLUTO	0,3		79,583	43,500	28,750	90,333	Máximo 62,583
(milhares de euros)	0,4		76,333	42,833	63,833	106,917	106,917
		Learning Rate	0,5	0,6	0,7	0,8	
	Momentum						
	0,1		12,926	14,443	11,210	15,076	Mínimo
ERRO MÉDIO	0,2		16,521	13,208	5,020	8,313	5,020 Média
(%)	0,3		16,930	12,361	5,584	16,918	Máximo 13,739
	0,4		26,148	7,923	16,922	20,318	26,148
		Learning Rate	0,5	0,6	0,7	0,8	
	Momentum						
	0,1		441,000	121,000	290,000	212,000	Mínimo
ERRO MÁXIMO	0,2		173,000	277,000	99,000	130,000	92,000 Média
ABSOLUTO	0,3		427,000	188,000	92,000	288,000	Máximo 237,063
(milhares de euros)	0,4		383,000	143,000	171,000	358,000	441,000
		Learning Rate	0,5	0,6	0,7	0,8	
	Momentum						
	0,1		74,619	46,774	46,624	52,475	Mínimo
ERRO MÁXIMO	0,2		27,504	68,564	20,886	30,108	14,791 Média
(%)	0,3		81,801	59,677	14,791	55,172	Máximo 59,050
	0,4		205,914	26,190	73,118	60,575	205,914
		Learning Rate	0,5	0,6	0,7	0,8	
	Momentum						
	0,1		0,00204	0,00380	0,00167	0,00179	Mínimo
ERRO MÉDIO	0,2		0,00302	0,00161	0,00119	0,00122	0,00119 Média
QUADRÁTICO	0,3		0,00196	0,00215	0,00145	0,00228	Máximo 0,00221
	0,4		0,00335	0,00169	0,00250	0,00363	0,00380

Tabela 4: Resumo dos resultados obtidos em Análise 1 (parâmetros NF/NM/V/S)

As figuras 35 e 36 apresentam, respectivamente, o gráfico com o menor e o maior erro médio absoluto obtido na fase de teste da rede neuronal.

Implementação




Figura 35: Menor erro médio absoluto em Análise 1 (parâmetros NF/NM/V/S)




Figura 36: Maior erro médio absoluto em Análise 1 (parâmetros NF/NM/V/S)

Implementação

Por fim para as previsões de 2008, foram ensaiados como parâmetros de entrada: número de funcionários (NF), número de máquinas (NM), volume de vendas do mesmo mês do ano anterior (V) e taxa de desemprego (TD). Os resultados obtidos são apresentados na tabela 5.

Previsões Vendas Mensais Ano 2008 - 4 Parâmetros - Back Propa								
<small>(Nº de Funcionários / Nº de Máquinas / Vendas do mesmo mês do Ano Anterior / Taxa de Desemprego)</small>								
<small>Nº de iterações de aprendizagem da rede = 500000</small>								
<small>Nº Elementos do Conjunto de Treino = 48</small>								
<small>Nº Elementos do Conjunto de Teste = 12</small>								
		Learning Rate	0,5	0,6	0,7	0,8		
	Momentum							
	0,1		57,833	47,583	69,000	78,750	Mínimo	
ERRO MÉDIO	0,2		75,250	39,167	135,500	45,250	39,167	Média
ABSOLUTO	0,3		45,000	72,333	60,500	92,500	Máximo	71,948
(milhares de euros)	0,4		55,083	79,500	76,000	121,917	135,500	
		Learning Rate	0,5	0,6	0,7	0,8		
	Momentum							
	0,1		12,386	10,303	25,134	14,701	Mínimo	
ERRO MÉDIO	0,2		16,214	9,132	29,572	9,144	9,132	Média
(%)	0,3		9,270	13,732	17,386	17,903	Máximo	16,209
	0,4		13,291	22,522	15,124	23,536	29,572	
		Learning Rate	0,5	0,6	0,7	0,8		
	Momentum							
	0,1		142,000	157,000	381,000	317,000	Mínimo	
ERRO MÁXIMO	0,2		228,000	170,000	278,000	135,000	124,000	Média
ABSOLUTO	0,3		162,000	124,000	179,000	257,000	Máximo	211,375
(milhares de euros)	0,4		171,000	262,000	175,000	244,000	381,000	
		Learning Rate	0,5	0,6	0,7	0,8		
	Momentum							
	0,1		34,409	38,861	204,839	66,878	Mínimo	
ERRO MÁXIMO	0,2		41,758	42,079	68,812	33,416	24,505	Média
(%)	0,3		40,099	24,505	96,237	43,486	Máximo	62,164
	0,4		44,086	140,860	29,611	44,689	204,839	
		Learning Rate	0,5	0,6	0,7	0,8		
	Momentum							
	0,1		0,00292	0,00216	0,00144	0,00149	Mínimo	
ERRO MÉDIO	0,2		0,00287	0,00347	0,00251	0,00451	0,00123	Média
QUADRÁTICO	0,3		0,00398	0,00257	0,00362	0,00382	Máximo	0,00304
	0,4		0,00123	0,00399	0,00402	0,00402	0,00451	

Tabela 5: Resumo dos resultados obtidos em Análise 1 (parâmetros NF/NM/V/TD)

As figuras 37 e 38 apresentam, respectivamente, o gráfico com o menor e o maior erro médio absoluto obtido na fase de teste da rede neuronal.

Implementação




Figura 37: Menor erro médio absoluto em Análise 1 (parâmetros NF/NM/V/TD)




Figura 38: Maior erro médio absoluto em Análise 1 (parâmetros NF/NM/V/TD)

Análise 2

Nesta análise foram utilizados 60 meses de histórico (2004 a 2008), na aprendizagem da rede, para prever as vendas dos 5 primeiros meses de 2009.

Foram seleccionados os mesmos parâmetros da análise anterior, tendo-se começado por escolher inicialmente os 4 seguintes: número de funcionários (NF), Produto Interno Bruto (PIB), + Índice de Preços no Consumidor (IPC) e taxa de desemprego (TD). A tabela 6 apresenta os resultados obtidos.

Previsões Vendas Mensais Ano 2009 - 4 Parâmetros - Back Pro								
[Nº de Funcionários / PIB / IPC / Taxa de Desemprego]								
Nº de iterações de aprendizagem da rede = 500000								
Nº Elementos do Conjunto de Treino = 60								
Nº Elementos do Conjunto de Teste = 5								
		Learning Rate	0,5	0,6	0,7	0,8		
	Momentum							
	0,1		32,000	74,200	84,200	120,400	Mínimo	
ERRO MÉDIO	0,2		76,400	77,000	66,600	82,400	32,000	Média
ABSOLUTO	0,3		104,600	61,200	144,400	53,400	Máximo	83,809
(milhares de euros)	0,4		60,400	109,333	111,500	82,917	144,400	
		Learning Rate	0,5	0,6	0,7	0,8		
	Momentum							
	0,1		8,475	19,310	26,305	35,041	Mínimo	
ERRO MÉDIO	0,2		25,309	24,295	15,451	24,156	8,475	Média
(%)	0,3		32,085	17,669	46,770	13,350	Máximo	23,051
	0,4		17,312	23,283	23,653	16,357	46,770	
		Learning Rate	0,5	0,6	0,7	0,8		
	Momentum							
	0,1		98,000	132,000	157,000	200,000	Mínimo	
ERRO MÁXIMO	0,2		135,000	164,000	190,000	108,000	89,000	Média
ABSOLUTO	0,3		171,000	106,000	304,000	120,000	Máximo	161,375
(milhares de euros)	0,4		89,000	201,000	207,000	200,000	304,000	
		Learning Rate	0,5	0,6	0,7	0,8		
	Momentum							
	0,1		30,818	41,509	49,371	74,074	Mínimo	
ERRO MÁXIMO	0,2		50,000	60,741	30,794	38,148	22,222	Média
(%)	0,3		54,984	34,084	97,749	22,222	Máximo	47,124
	0,4		32,963	51,613	51,075	33,841	97,749	
		Learning Rate	0,5	0,6	0,7	0,8		
	Momentum							
	0,1		0,00458	0,00502	0,00433	0,00380	Mínimo	
ERRO MÉDIO	0,2		0,00295	0,00434	0,00445	0,00605	0,00166	Média
QUADRÁTICO	0,3		0,00351	0,00437	0,00444	0,00505	Máximo	0,00387
	0,4		0,00348	0,00186	0,00196	0,00166	0,00605	

Tabela 6: Resumo dos resultados obtidos em Análise 2 (parâmetros NF/PIB/IPC/TD)

As figuras 39 e 40 apresentam, respectivamente, o gráfico com o menor e o maior erro médio absoluto obtido na fase de teste da rede neuronal.

Implementação




Figura 39: Menor erro médio absoluto em Análise 2 (parâmetros NF/PIB/IPC/TD)

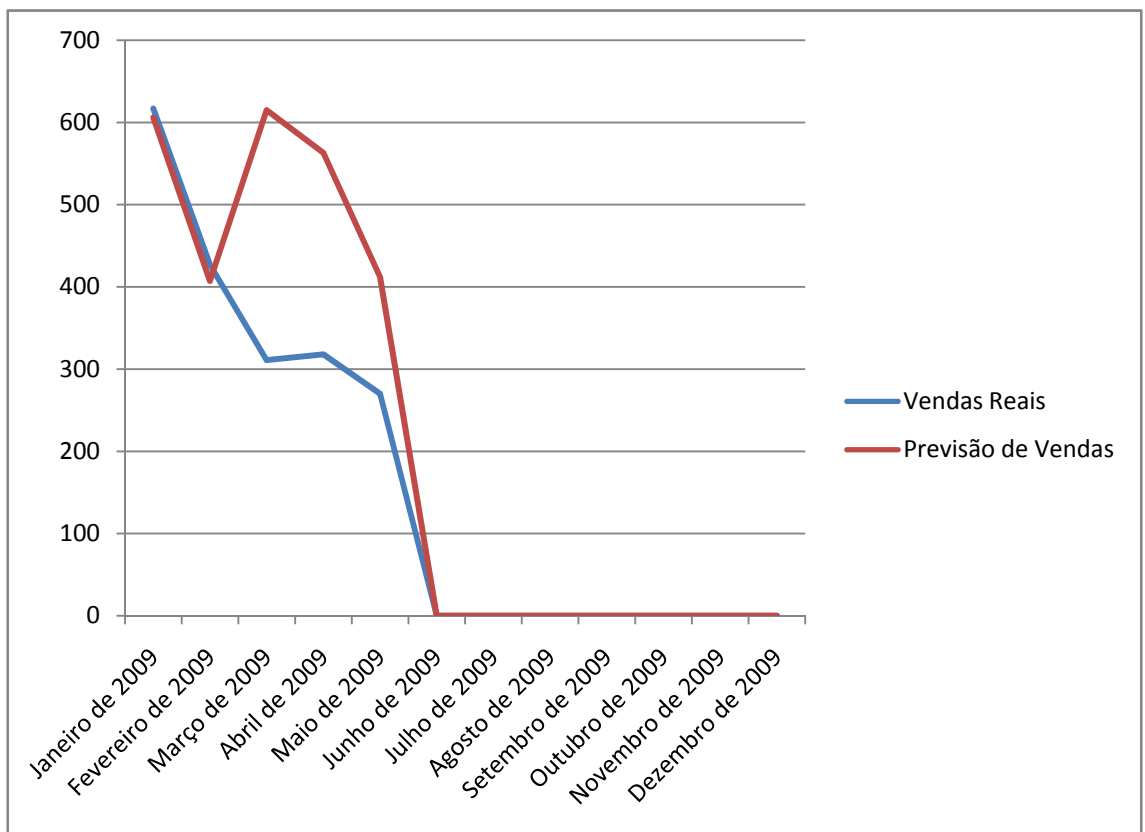


Figura 40: Maior erro médio absoluto em Análise 2 (parâmetros NF/PIB/IPC/TD)

Implementação

Em seguida foram ensaiados como parâmetros de entrada o número de funcionários (NF), o número de máquinas (NM), o volume de vendas do mesmo mês do ano anterior (V) e o Índice de Preços no Consumidor (IPC). A tabela 7 apresenta os resultados obtidos.

Previsões Vendas Mensais Ano 2009 - 4 Parâmetros - Back Propa								
<small>(Nº de Funcionários / Nº de Máquinas / Vendas do mesmo mês do Ano Anterior / I.P.C.)</small>								
<small>Nº de iterações de aprendizagem da rede = 500000</small>								
<small>Nº Elementos do Conjunto de Treino = 60</small>								
<small>Nº Elementos do Conjunto de Teste = 5</small>								
		Learning Rate	0,5	0,6	0,7	0,8		
		Momentum						
	0,1							
ERRO MÉDIO	0,2		52,600	98,800	79,800	37,600	Mínimo	
ABSOLUTO	0,3		45,600	87,800	76,800	70,200	36,400	Média
(milhares de euros)	0,4		80,000	36,400	124,800	79,800	Máximo	78,713
			86,000	82,200	100,800	120,200	124,800	
		Learning Rate	0,5	0,6	0,7	0,8		
		Momentum						
	0,1							
ERRO MÉDIO	0,2		14,970	30,331	24,197	8,680	Mínimo	
(%)	0,3		12,292	27,439	24,050	20,952	8,680	Média
	0,4		26,701	11,718	39,605	26,728	Máximo	24,477
			27,138	26,618	31,822	38,385	39,605	
		Learning Rate	0,5	0,6	0,7	0,8		
		Momentum						
	0,1							
ERRO MÁXIMO	0,2		80,000	164,000	151,000	109,000	Mínimo	
ABSOLUTO	0,3		72,000	139,000	122,000	182,000	72,000	Média
(milhares de euros)	0,4		147,000	137,000	243,000	160,000	Máximo	150,188
			158,000	139,000	201,000	199,000	243,000	
		Learning Rate	0,5	0,6	0,7	0,8		
		Momentum						
	0,1							
ERRO MÁXIMO	0,2		29,630	52,733	48,553	17,666	Mínimo	
(%)	0,3		23,151	44,695	45,185	57,233	17,666	Média
	0,4		48,148	43,082	76,415	59,259	Máximo	49,148
			50,804	51,481	64,630	73,704	76,415	
		Learning Rate	0,5	0,6	0,7	0,8		
		Momentum						
	0,1							
ERRO MÉDIO	0,2		0,00272	0,00272	0,00354	0,00400	Mínimo	
QUADRÁTICO	0,3		0,00220	0,00165	0,00165	0,00284	0,00147	Média
	0,4		0,00220	0,00248	0,00185	0,00266	Máximo	0,00239
			0,00180	0,00175	0,00147	0,00268	0,00400	

Tabela 7: Resumo dos resultados obtidos em Análise 2 (parâmetros NF/NM/V/IPC)

As figuras 41 e 42 apresentam, respectivamente, o gráfico com o menor e o maior erro médio absoluto obtido na fase de teste da rede neuronal.

Implementação




Figura 41: Menor erro médio absoluto em Análise 2 (parâmetros NF/NM/V/IPC)




Figura 42: Maior erro médio absoluto em Análise 2 (parâmetros NF/NM/V/IPC)

Implementação

De seguida foram ensaiados como parâmetros de entrada o número de funcionários (NF), o número de máquinas (NM), o volume de vendas do mesmo mês do ano anterior e o Produto Interno Bruto (PIB). Os resultados obtidos são apresentados na tabela 8.

Previsões Vendas Mensais Ano 2009 - 4 Parâmetros - Back Propa							
<small>(Nº de Funcionários / Nº de Máquinas / Vendas do mesmo mês do Ano Anterior / P.I.B.)</small>							
<small>Nº de iterações de aprendizagem da rede = 500000</small>							
<small>Nº Elementos do Conjunto de Treino = 60</small>							
<small>Nº Elementos do Conjunto de Teste = 5</small>							
		Learning Rate	0,5	0,6	0,7	0,8	
		Momentum					
	0,1						
ERRO MÉDIO	0,2		109,400	64,200	87,400	76,800	Mínimo
ABSOLUTO	0,3		118,600	79,800	112,400	82,800	64,200 Média
(milhares de euros)	0,4		92,000	70,000	72,000	64,200	Máximo 92,363
			109,800	90,800	108,200	139,400	139,400
		Learning Rate	0,5	0,6	0,7	0,8	
		Momentum					
	0,1						
ERRO MÉDIO	0,2		36,432	18,407	29,086	25,888	Mínimo
(%)	0,3		38,510	25,196	35,200	25,730	17,219 Média
	0,4		30,703	23,764	23,725	17,219	Máximo 29,702
			35,288	30,184	34,652	45,247	45,247
		Learning Rate	0,5	0,6	0,7	0,8	
		Momentum					
	0,1						
ERRO MÁXIMO	0,2		203,000	106,000	168,000	155,000	Mínimo
ABSOLUTO	0,3		202,000	132,000	188,000	126,000	106,000 Média
(milhares de euros)	0,4		177,000	167,000	136,000	123,000	Máximo 168,813
			186,000	178,000	187,000	267,000	267,000
		Learning Rate	0,5	0,6	0,7	0,8	
		Momentum					
	0,1						
ERRO MÁXIMO	0,2		75,185	39,259	62,222	57,407	Mínimo
(%)	0,3		74,815	48,889	69,630	46,667	32,593 Média
	0,4		65,556	61,852	50,370	32,593	Máximo 60,355
			68,889	57,235	69,259	85,852	85,852
		Learning Rate	0,5	0,6	0,7	0,8	
		Momentum					
	0,1						
ERRO MÉDIO	0,2		0,00324	0,00374	0,00332	0,00342	Mínimo
QUADRÁTICO	0,3		0,00241	0,00351	0,00431	0,00219	0,00211 Média
	0,4		0,00347	0,00235	0,00211	0,00448	Máximo 0,00310
			0,00280	0,00256	0,00293	0,00280	0,00448

Tabela 8: Resumo dos resultados obtidos em Análise 2 (parâmetros NF/NM/V/PIB)

As figuras 43 e 44 apresentam, respectivamente, o gráfico com o menor e o maior erro médio absoluto obtido na fase de teste da rede neuronal.

Implementação




Figura 43: Menor erro médio absoluto em Análise 2 (parâmetros NF/NM/V/PIB)




Figura 44: Maior erro médio absoluto em Análise 2 (parâmetros NF/NM/V/PIB)

Implementação

Em seguida foram ensaiados como parâmetros de entrada: o número de funcionários (NF), o número de máquinas (NM), o volume de vendas do mesmo mês do ano anterior (V) e o valor do stock do mês anterior (S). A tabela 9 apresenta os resultados obtidos.

Previsões Vendas Mensais Ano 2009 - 4 Parâmetros - Back Propa								
(Nº de Funcionários / Nº de Máquinas / Vendas do mesmo mês do Ano Anterior / Stock Fim do Mês Anterior)								
Nº de iterações de aprendizagem da rede = 500000								
Nº Elementos do Conjunto de Treino = 60								
Nº Elementos do Conjunto de Teste = 5								
		Learning Rate	0,5	0,6	0,7	0,8		
	Momentum							
	0,1		23,000	95,800	81,800	98,800	Mínimo	
ERRO MÉDIO	0,2		110,600	89,800	123,200	85,000	23,000	Média
ABSOLUTO	0,3		77,000	83,800	117,800	105,400	Máximo	86,000
(milhares de euros)	0,4		106,600	83,200	59,400	34,800	123,200	
		Learning Rate	0,5	0,6	0,7	0,8		
	Momentum							
	0,1		7,641	30,155	22,933	31,872	Mínimo	
ERRO MÉDIO	0,2		34,673	29,522	38,210	27,286	7,641	Média
(%)	0,3		25,425	27,048	38,339	35,036	Máximo	27,452
	0,4		35,121	28,388	17,251	10,325	38,339	
		Learning Rate	0,5	0,6	0,7	0,8		
	Momentum							
	0,1		66,000	166,000	131,000	178,000	Mínimo	
ERRO MÁXIMO	0,2		197,000	178,000	197,000	153,000	65,000	Média
ABSOLUTO	0,3		146,000	199,000	217,000	190,000	Máximo	161,375
(milhares de euros)	0,4		190,000	190,000	119,000	65,000	217,000	
		Learning Rate	0,5	0,6	0,7	0,8		
	Momentum							
	0,1		24,444	61,481	41,111	65,926	Mínimo	
ERRO MÁXIMO	0,2		63,344	65,926	72,963	56,667	24,074	Média
(%)	0,3		54,074	63,987	69,775	70,370	Máximo	57,072
	0,4		70,370	70,370	38,264	24,074	72,963	
		Learning Rate	0,5	0,6	0,7	0,8		
	Momentum							
	0,1		0,00258	0,00258	0,00328	0,00388	Mínimo	
ERRO MÉDIO	0,2		0,00296	0,00296	0,00381	0,00381	0,00258	Média
QUADRÁTICO	0,3		0,00381	0,00301	0,00301	0,00301	Máximo	0,00317
	0,4		0,00301	0,00301	0,00302	0,00301	0,00388	

Tabela 9: Resumo dos resultados obtidos em Análise 2 (parâmetros NF/NM/V/S)

As figuras 45 e 46 apresentam, respectivamente, o gráfico com o menor e o maior erro médio absoluto obtido na fase de teste da rede neuronal.

Implementação




Figura 45: Menor erro médio absoluto em Análise 2 (parâmetros NF/NM/V/S)




Figura 46: Maior erro médio absoluto em Análise 2 (parâmetros NF/NM/V/S)

Implementação

Por fim para as previsões de 2008, foram ensaiados com os parâmetros de entrada: número de funcionários (NF), número de máquinas (NM), volume de vendas do mesmo mês do ano anterior (V) e a taxa de desemprego (TD). Os resultados obtidos são apresentados na tabela 10.

Previsões Vendas Mensais Ano 2009 - 4 Parâmetros - Back Propa							
<small>(Nº de Funcionários / Nº de Máquinas / Vendas do mesmo mês do Ano Anterior / Taxa de Desemprego)</small>							
<small>Nº de iterações de aprendizagem da rede = 500000</small>							
<small>Nº Elementos do Conjunto de Treino = 60</small>							
<small>Nº Elementos do Conjunto de Teste = 5</small>							
		Learning Rate	0,5	0,6	0,7	0,8	
	Momentum						
	0,1		71,000	122,200	98,600	140,200	Mínimo
ERRO MÉDIO	0,2		57,400	84,800	87,600	82,000	57,400 Média
ABSOLUTO	0,3		108,600	92,400	68,800	60,800	Máximo 88,888
(milhares de euros)	0,4		135,000	77,400	64,800	70,600	140,200
		Learning Rate	0,5	0,6	0,7	0,8	
	Momentum						
	0,1		23,369	36,984	31,550	45,486	Mínimo
ERRO MÉDIO	0,2		14,541	26,066	29,384	25,370	12,932 Média
(%)	0,3		34,427	30,037	19,356	12,932	Máximo 27,372
	0,4		42,856	24,924	19,963	20,706	45,486
		Learning Rate	0,5	0,6	0,7	0,8	
	Momentum						
	0,1		139,000	206,000	169,000	273,000	Mínimo
ERRO MÁXIMO	0,2		128,000	138,000	175,000	158,000	95,000 Média
ABSOLUTO	0,3		170,000	168,000	95,000	173,000	Máximo 163,813
(milhares de euros)	0,4		237,000	139,000	113,000	140,000	273,000
		Learning Rate	0,5	0,6	0,7	0,8	
	Momentum						
	0,1		51,481	76,296	62,593	101,111	Mínimo
ERRO MÁXIMO	0,2		26,667	51,111	56,270	58,519	26,667 Média
(%)	0,3		62,963	54,019	35,185	28,039	Máximo 55,649
	0,4		87,778	51,481	41,852	45,016	101,111
		Learning Rate	0,5	0,6	0,7	0,8	
	Momentum						
	0,1		0,00301	0,00175	0,00495	0,00311	Mínimo
ERRO MÉDIO	0,2		0,00253	0,00374	0,00313	0,00372	0,00175 Média
QUADRÁTICO	0,3		0,00300	0,00287	0,00392	0,00385	Máximo 0,00321
	0,4		0,00290	0,00239	0,00259	0,00397	0,00495

Tabela 10: Resumo dos resultados obtidos em Análise 2 (parâmetros NF/NM/V/TD)

As figuras 47 e 48 apresentam, respectivamente o gráfico com o menor e o maior erro médio absoluto obtido na fase de teste da rede neuronal.

Implementação




Figura 47: Menor erro médio absoluto em Análise 2 (parâmetros NF/NM/V/TD)




Figura 48: Maior erro médio absoluto em Análise 2 (parâmetros NF/NM/V/TD)

4.4 Conclusões

Os testes exaustivos realizados, para as previsões de 2008 e de 2009, apontam no sentido de este método ser aplicável na previsão de vendas, com erros médios e máximos aceitáveis para este tipo de negócio.

Será natural que à medida que a rede tenha mais dados para a sua aprendizagem que estes erros venham a decrescer.

No entanto erros médios na ordem dos 13%, como os obtidos nas previsões de 2008, podem ser considerados altamente encorajadores para trabalhos futuros.

5 Conclusões e Trabalho Futuro

Em termos de trabalho futuro, será dada prioridade aos restantes módulos do ERP, tendo sempre em atenção a integração total e funcionalidade entre e de todos os módulos. Esta decisão obviamente tem também um cariz comercial, uma vez que este ERP é uma forte aposta da Dinâmica, que sem o ter “vendável” tornará o seu futuro menos promissor.

Todo o trabalho desenvolvido com o método de redes neuronais, “*Back Propagation*”, será devidamente utilizado em novas situações, em que o cariz de aprendizagem e previsão seja útil.

É neste momento uma certeza que o método “*Back Propagation*” se revela eficaz na previsão de vendas mensais, baseado numa boa selecção dos parâmetros pré-determinados e num histórico que por cada ano que passa se torna mais “rico”.

5.1 Satisfação dos Objectivos

Como já foi referido anteriormente, o principal objectivo deste projecto foi a criação de um módulo comercial para o novo ERP da Dinâmica, que substituisse o antigo, sendo inovador em termos tecnológicos, totalmente gráfico e com um nível de funcionalidades na “crista da onda”.

Ao nível do primeiro, na tecnologia, a inovação e a ambição estiveram bem presentes. Quem aposta na tecnologia Java / *PostgreSql*, depois ter trabalhado muitos anos com o sistema operativo *Twin-Server*, linguagem de programação ABAL e motor de base de dados CRITERIA merece esses adjectivos. Naturalmente que os objectivos em termos de tecnologia foram completamente satisfeitos, claro que se “partiu muita pedra”, e ainda há muita por partir, mas estes tipos de projectos são mesmo assim.

Ao nível da apresentação esta tecnologia como sabemos é totalmente orientada ao bit, logo também aqui se deu um salto qualitativo extraordinário, estando naturalmente os objectivos satisfeitos.

Em termos de funcionalidades também se evoluiu muitíssimo, não é de mais lembrar que bastava só aproveitar todas as potencialidades do Java, em termos de bibliotecas e constantes actualizações de versões, para esse salto ser natural.

Sintetizando, passar de um módulo comercial de um ERP orientado ao carácter, para um módulo comercial de um ERP, assente nas mais recentes tecnologias dá como uma sensação de missão cumprida.

5.2 Trabalho Futuro

A curto prazo integrar todo o esforço produzido neste projecto em termos de utilização do método de redes neuronais “*Back Propagation*” para a previsão de vendas mensais, na classe já desenvolvida do Quadro de Bordo. Para isso será necessário ao nível dos parâmetros da empresa, permitir aos utilizadores informarem os históricos de cada um dos parâmetros de entrada seleccionados, por forma à classe poder efectuar o “output” com as respectivas previsões para o ano n+1.

Será ainda necessário enriquecer o módulo comercial com mais alguns relatórios essenciais para uma mais correcta exploração do ERP.

A médio prazo, continuar o desenvolvimento dos módulos em falta, utilizando o “espírito” do desenvolvimento seguido até aqui, quer em termos de tecnologias quer em termos de integração.

REFERÊNCIAS

- [Ver96] François B. Verdant, Enterprise Modeling and Integration (Hardcover), Chapman & Hall, 1996
- [AK01] Anderson Kristin & Kerr Carol, Customer Relationship Management, McGraw-Hill, 2001
- [LL06] Kenneth C. Laudon & Jane P. Laudon , Management Information Systems: Managing the Digital Firm (Hardcover) , Prentice Hall, 2006
- [SS01] Garth Saloner & A.Michael Spence, Creating and Capturing Value: Perspectives and Cases on Electronic Commerce (Hardcover), October 2001
- [WN04] Willard N. Ander e Neil Z. Stern, Winning at Retail – Developing a Sustained Model for Retail Success. John Wiley & Sons, Inc., 2004
- [Roj96] R.Rojas, Neural networks. A systematic approach. *Springer Berlin, 1996*
- [Fau94] Laurene Fausett, Fundamentals of Neural Networks. Architectures, algorithms and applications, Prentice Hall, Inc.,1994
- [Day07] Judith E. Dayoff, Neural network architectures : an introduction, 2007
- [Zor07] Alexey Zorin, Stock Price Prediction: Kohonen versus BackPropagation, 2007
- [TMV06] Frank M. Thiesing, Ulrich Middelberg, Oliver Vornberger, Parallel Back-Propagation for Sales Prediction on Transputer Systems, 2006
- [CLF09] Pei-Chann Chang, Chen-Hao Liu, Chin-Yuan Fan, Data Clustering and fuzzy neural network for sales forecasting: A case study in printed circuit board industry, 2009
- [KX98] R.J. Kuo, K.C. Xue, An intelligent sales forecasting system through integration of artificial neural network and fuzzy neural network, 1998