

UNIVERSIDADE SAGRADO CORAÇÃO

RAFAEL FRENHE BERALDO

**MONITORAMENTO DE SERVIÇOS WEB PARA
PREVER POSSÍVEIS FALHAS**

BAURU
2013

RAFAEL FRENHE BERALDO

**MONITORAMENTO DE SERVIÇOS WEB PARA
PREVER POSSÍVEIS FALHAS**

Trabalho de conclusão de curso apresentado ao Centro de Ciências Exatas e Sociais Aplicadas como parte dos requisitos para obtenção do título de Bacharel em Ciência da Computação, sob a orientação do Prof. Me. Anderson Francisco Talon.

BAURU
2013

B482r Beraldo, Rafael Frenhe

Monitoramento de serviços web para prever possíveis falhas / Rafael Frenhe Beraldo -- 2013.
48f. : il.

Orientador: Prof. Me. Anderson Francisco Talon.

Trabalho de conclusão de curso (Graduação em Ciência da Computação) – Universidade do Sagrado Coração – Bauru – SP.

1. Monitoramento. 2. Inteligência Artificial. 3. Serviços Web. I. Talon, Anderson Francisco. II. Título.

RAFAEL FRENHE BERALDO

**MONITORAMENTO DE SERVIÇOS WEB PARA PREVER POSSÍVEIS
FALHAS**

Trabalho de Conclusão de Curso apresentado ao Centro de Ciências Exatas e Sociais Aplicadas da Universidade Sagrado Coração como parte dos requisitos para obtenção do título de bacharel em Ciência da Computação, sob orientação do Prof. Me. Anderson Francisco Talon.

Banca examinadora:

Prof. Me. Anderson Francisco Talon
Universidade Sagrado Coração

Prof. Dr. Élvio Gilberto da Silva
Universidade Sagrado Coração

Prof. Me. William Carlos Galvão
Universidade Sagrado Coração

Bauru, 21 de junho de 2013.

RESUMO

Organizações atualmente tendem a trabalhar cooperativamente para atingir objetivos em comum e focarem nas atividades principais do negócio, um dos métodos para que isso ocorra é em forma de terceirização de serviços. A Computação Orientada a Serviços sugere um modelo para o desenvolvimento de sistemas distribuídos, onde fornecedores desenvolvem seus serviços e os guardam em seus servidores públicos para que consumidores de tais serviços possam utilizá-los. Contratos eletrônicos são negociados e definidos previamente entre as partes para manter a integridade dos sistemas, porém muitos fatores podem impedir que as regras dos contratos sejam seguidas, portanto é importante que os serviços sejam monitorados para que comportamentos indesejáveis sejam detectados. Este trabalho apresenta um método de monitoramento do tempo de resposta das requisições de serviços web para previsão de quebra de contrato com auxílio de inteligência artificial.

Palavras-chave: Monitoramento. Inteligência Artificial. Serviços Web.

ABSTRACT

Organizations today tend to work cooperatively to achieve common goals and focus on core business activities, one of the methods for this is outsourcing services. The Service-Oriented Computing suggests a model for developing distributed systems, where suppliers develop their services and keep them in their public servants so that consumers of such services can use them. Electronic contracts are negotiated and defined previously between the parties to maintain the integrity of systems, but many factors can prevent the contract rules are followed, so it is important that services are monitored so that undesirable behaviors are detected. This paper presents a method for monitoring the response time of web service requests for predicting breach of contract with the aid of artificial intelligence.

Keywords: Monitoring. Artificial Intelligence. Web Services.

LISTA DE ILUSTRAÇÕES

Figura 1 - Monitoração.	10
Figura 2 - Associação entre conjunto de dados e classes.....	13
Figura 3 - Registros agrupados em três clusters.....	14
Figura 4 - Regressão Linear.....	16
Figura 5 - Regressão Não-linear.	16
Figura 6 - AOS (Arquitetura Orientada a Serviço).....	17
Figura 7 - Gráfico dos dados aleatórios.....	19
Figura 8 - Gráfico dos dados manipulados.....	20
Figura 9 - Gráfico dos dados reais.	20
Figura 10 - Exemplo do algoritmo em execução.	22

LISTA DE ABREVIATURAS E SIGLAS

- AOS** - Arquitetura Orientada a Serviços
- COS** - Computação Orientada a Serviços
- IA** - Inteligência Artificial
- KDD** - *Knowledge Discovery in Databases*
- HTTP** - *Hypertext Transfer Protocol*
- MD** - Mineração de Dados
- PHP** - Personal Home Page
- QoS** - *Quality of Service*
- RNA** - Redes Neurais Artificiais
- SOAP** - *Simple Object Access Protocol*
- TCP** - *Transmission Control Protocol*
- TR** - Tempo de resposta
- UDDI** - *Universal Description, Discovery and Integration*
- UT** - Unidade de tempo
- UTF-8** - *8-bit Unicode Transformation Format*
- W3C** - *World Wide Web Consortium*
- WSDL** - *Web Services Description Language*
- WWW** - *World Wide Web*
- XML** - Extensible Markup Language

SUMÁRIO

1 INTRODUÇÃO	5
1.1 OBJETIVOS.....	6
1.1.1 Objetivo Geral.....	6
1.1.2 Objetivo Específico	6
1.2 JUSTIFICATIVA.....	6
2 FUNDAMENTAÇÃO TEÓRICA	7
2.1 ARQUITETURA ORIENTADA A SERVIÇOS.....	7
2.2 SERVIÇOS	7
2.3 SERVIÇOS WEB	7
2.3.1 Publicação	8
2.3.2 Descrição	8
2.3.3 Invocação.....	8
2.3.4 Descoberta.....	8
2.3.5 Composição.....	8
2.4 CONTRATOS ELETRÔNICOS.....	9
2.5 MONITORAMENTO.....	9
2.6 DESCOBERTA DE CONHECIMENTO EM BANCO DE DADOS (KDD)	11
2.7 INTELIGÊNCIA ARTIFICIAL.....	12
2.7.1 Mineração de Dados	12
2.7.2 Tarefas da Mineração de Dados.....	12
2.7.3 Métodos e técnicas da Mineração de Dados	15
3 PROTÓTIPO	17
4 RESULTADOS.....	19
6 CONSIDERAÇÕES FINAIS	31
REFERÊNCIAS.....	32

1 INTRODUÇÃO

Organizações atualmente tendem a trabalhar cooperativamente para atingir objetivos em comum e focarem nas atividades principais do negócio, um dos métodos para que isso ocorra é em forma de terceirização de serviços. Serviços web são aplicações cujo objetivo é prover uma funcionalidade capaz de ser invocada por aplicações de consumidores de tais serviços, estes são a mais simples utilização de AOS (Arquitetura Orientada a Serviço) aplicando os principais padrões SOAP (*Simple Object Access Protocol*) e WSDL (*Web Services Description Language*) (MICHLMAYR et al., 2009; POSTAL, 2011).

O modelo de COS (Computação Orientada a Serviços) sugere que, fornecedores desenvolvam seus serviços e os publiquem na linguagem padrão WSDL para que consumidores de tais serviços possam utilizá-los (CHINNICI et al., 2006). É também comum encontrarmos serviços compostos, que são desenvolvidos para cumprir objetivos mais extensos (POSTAL, 2011).

Contratos eletrônicos são negociados e definidos previamente entre as partes para manter a integridade dos sistemas, porém algumas questões como sobrecarga de pedidos ou até mesmo alteração dos serviços pelos fornecedores podem impedir que as regras dos contratos sejam seguidas. Precisam ser criados de modo que possam ser executados e monitorados (SANTOS, 2011).

Segundo Baresi e Guinea (2005), o monitoramento contínuo dos contratos e serviços é uma das soluções para estas objeções. Com os monitores operando em tempo de execução com auxílio de técnicas de programação defensiva é possível que comportamentos indesejáveis sejam detectados e tratados.

O foco do trabalho foi desenvolver um monitoramento do tempo de resposta dos serviços através da análise de dados de execuções anteriores, de modo que o contrato possa ser revisado e renegociado antes da quebra do mesmo.

IA (Inteligência Artificial) estuda a forma de pensar do ser humano e busca implementar isso em linguagem de máquina, é exatamente o que buscamos quando se trata de previsão de informação. O monitoramento do tempo de resposta das requisições utilizando IA visa prever tais irregularidades, como a quebra do contrato, para que providências sejam tomadas.

1.1 OBJETIVOS

1.1.1 Objetivo Geral

Desenvolver um monitoramento do tempo de resposta das requisições de Web Services para previsão utilizando técnicas de Inteligência Artificial.

1.1.2 Objetivo Específico

- Pesquisar sobre previsão de dados e Inteligência Artificial.
- Estudar algoritmos de Mineração de Dados.
- Entender o funcionamento de Serviços Web e principalmente a entidade de Monitoramento.
- Desenvolver um monitor analisando os dados de eventos passados, aplicando a técnica de Mineração de Dados.

1.2 JUSTIFICATIVA

A entidade de monitoramento dos web services é uma das partes mais importantes, pois é no monitoramento que é possível prever uma possível quebra de contrato, e caso o monitor diga que uma possível quebra esteja prevista, as entidades então devem se comunicar para que o serviço seja recontratado. Sem essa previsão, os contratos poderiam ser quebrados, acarretando em multas.

2 FUNDAMENTAÇÃO TEÓRICA

2.1 ARQUITETURA ORIENTADA A SERVIÇOS

A Arquitetura Orientada a Serviços (AOS) é uma evolução da computação distribuída com base no modelo request/reply para aplicações cliente e fornecedores (KODALI, 2005). Na qual é capaz de suportar a orientação a serviços, cujo princípio fundamental prega que as funcionalidades implementadas pelas aplicações sejam disponibilizadas na forma de serviços (POSTAL, 2011; LUBLINSKY, 2007). Sendo assim, AOS tem como princípio a prestação de serviços, colocando em relevo à gestão de serviços e ao cliente.

2.2 SERVIÇOS

Um serviço, do ponto de vista da arquitetura AOS, é uma função de um sistema computacional que é disponibilizado para outros sistemas, na qual deve funcionar independente do estado de outros serviços, com exceção de serviços compostos (SOBRINHO, 2011).

2.3 SERVIÇOS WEB

Serviços web são aplicações cujo objetivo é prover uma funcionalidade capaz de ser invocada por aplicações dos consumidores de, facilitando e diminuindo o tempo de desenvolvimento de novos serviços (POSTAL, 2011).

Booth et al. (2004) considera que um serviço web é um sistema de software projetado para suportar interação entre máquinas sobre uma rede, além de uma interface em formato processável de máquina. Outros sistemas interagem com o serviço web de uma maneira prescrita por sua descrição usando mensagens SOAP, tipicamente exportadas utilizando HTTP e XML dentre outras tecnologias padrões de web.

A tecnologia de serviços web gera aumentos de produtividade e facilidade para a gerencia da tecnologia da informação devido a capacidade de reutilização de software e integração de aplicações desenvolvidas em plataformas e ferramentas distintas (SOBRINHO, 2011).

Um serviço web possui cinco operações fundamentais para o funcionamento, detalhadas abaixo, e são definidas pelo modelo AOS e afetam diretamente o método que o serviço irá operar e interagir com consumidores e usuários (POSTAL, 2011).

2.3.1 Publicação

Refere-se a operação em que os provedores de serviços web divulgam seus serviços (ERL, 2005). UDDI é um dos protocolos mais utilizados para a publicação através de diretórios e registros da web.

2.3.2 Descrição

De acordo com Maamar et al. (2010), a descrição de serviços web determina propriedades funcionais e não-funcionais dos sistemas. Ela fornece acesso ao web service e outros serviços de forma automática, como um de seus propósitos. Booth et al. (2004) sugere que, a elaboração de uma descrição seja feita utilizando a linguagem web WSDL, que é baseada em XML.

2.3.3 Invocação

"Ocorre no momento em que outros serviços chamam a função referente a um serviço web [...]" (MAAMAR et al., 2010 citado por POSTAL, 2011, p.15). É feita utilizando protocolo SOAP que funciona como um padrão para a comunicação entre os serviços, já que cada um pode ser feito em plataformas e linguagens diferentes.

2.3.4 Descoberta

Encontra através de requisições de consumidores, o serviço web que melhor atenda às necessidades requeridas por tais usuários (MAAMAR et al., 2010). A descoberta só é possível devido às descrições publicadas em protocolos, como o UDDI (POSTAL, 2011).

2.3.5 Composição

Para reduzir tempo e custo de desenvolvimento, além de maior facilidade de manutenção das aplicações, é possível que serviços contenham em sua implementação invocações de serviços mais simples. Para que isso ocorra, é necessário que seja descrito por uma linguagem capaz de organizar os vários serviços utilizados para que o objetivo do negócio seja atingido (WESKE, 2007).

Atualmente a linguagem padrão para a descrição de tais processos é a WS-BPEL (ALVES et al., 2007).

2.4 CONTRATOS ELETRÔNICOS

Segundo Fantinato (2007) um contrato eletrônico é um documento eletrônico usado para representar um acordo entre organizações parceiras que estão executando processos de negócio por meio da Internet, nos quais os serviços negociados são serviços eletrônicos. Estes também podem variar desde um simples pedido de compra para a venda de produtos pela Internet até documentos extremamente complexos para um acordo comercial entre parceiros de negócio multinacionais.

Conforme Santos (2011, p.5) o ciclo de vida de um contrato consiste de:

[...] **Estabelecimento de contratos eletrônicos:** processo de decisão que estabelece como o processo de negócio deverá ser realizado entre a organização fornecedora e a organização consumidora. Durante a negociação são definidas as partes envolvidas, os serviços a serem prestados e as cláusulas contratuais que devem ser cumpridas durante a realização do contrato.

Execução e monitoramento do contrato eletrônico: execução e cumprimento dos termos estabelecidos no contrato eletrônico, por meio da execução dos serviços eletrônicos previstos e cumprimento das cláusulas contratuais estabelecidas. Para garantir o cumprimento das cláusulas, elas devem ser monitoradas durante a execução dos serviços eletrônicos. A organização consumidora também pode executar operações de monitoramento do processo conforme restrições estabelecidas no contrato eletrônico.

Renegociação do contrato eletrônico: caso algumas das cláusulas não sejam cumpridas, o contrato eletrônico pode ser renegociado para atender as novas condições de execução do processo.

2.5 MONITORAMENTO

Monitoramento de serviços requer que uma característica crítica seja realizada: serviços sejam monitorados e acompanhados. Isso pode ser feito de forma que informações geradas durante a execução sejam registradas, apresentando estatísticas para que medidas de correções sejam tomadas (PAPAZOGLU et al., 2008).

Segundo Garcia (2007, p. 44) existem "[...] dois tipos de monitoração: a local, na qual o monitor observa um serviço identificando as falhas deste, e a remota, na qual os detectores são responsáveis por monitorar uns aos outros [...]".

A monitoração local, representadas com as setas menores na Figura 1, acontece em forma de troca de mensagens entre os monitores e serviços, é responsável pela monitoração apenas dos serviços disponibilizados na mesma máquina na qual é executado, e podem ser feitos utilizando métodos Pull ou Push. No método Pull os serviços enviam mensagens periodicamente indicando que estão ativos, se o monitor não receber a mensagem num certo limite de tempo significa que o serviço está com falhas. No método Push os monitores enviam mensagens perguntando se o serviço está ativo, e novamente, se a mensagem não chegar num certo limite de tempo significa que o serviço está com falhas (GARCIA, 2007).

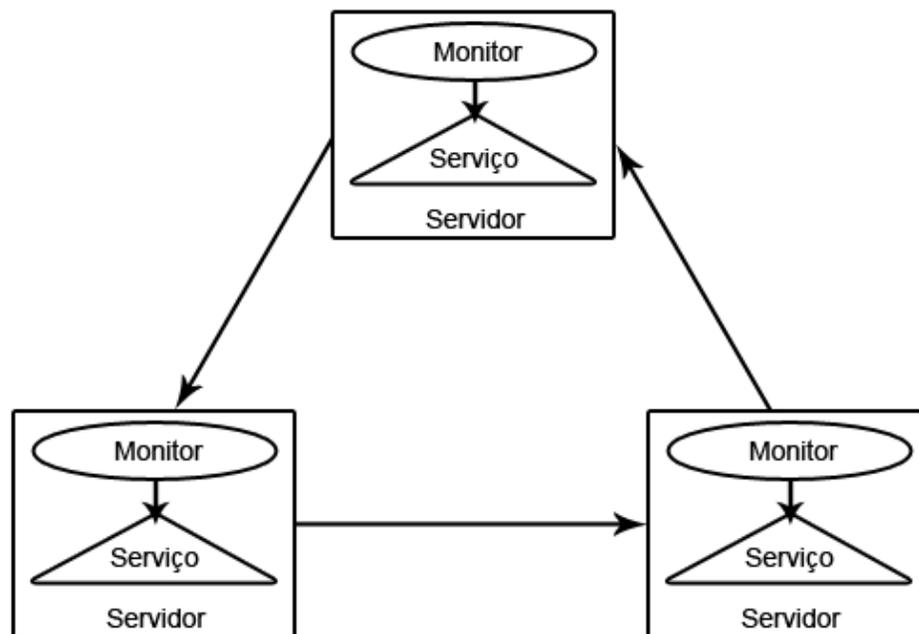


Figura 1 - Monitoração.
Fonte: Elaborado pelo autor (2013).

A respeito da monitoração remota, representadas com as setas maiores na Figura 1, Garcia (2007, p.45) afirma que os monitores "[...] irão monitorar uns aos outros, realizando a detecção de falhas provocadas pela parada de equipamentos que possuem serviços rodando." Serão monitorados em forma de lista circular: cada membro monitora o vizinho posterior, e o último monitora o primeiro.

2.6 DESCOBERTA DE CONHECIMENTO EM BANCO DE DADOS (KDD)

O termo KDD (*Knowledge Discovery in Databases*) foi formalizado em 1989 para atender os processos referentes à busca de conhecimento a partir de bases de dados. Uma das definições mais populares foi proposta por um grupo de pesquisadores (FAYYAD et al., 1996b, p. 30) onde dizia que "[...] KDD é um processo, de várias etapas, não trivial, interativo e iterativo, para identificação de padrões compreensíveis, válidos, novos e potencialmente úteis a partir de grandes conjuntos de dados."

Goebel e Gruenwald (1999) afirmam que, o termo KDD é usado para representar o processo de tornar dados de baixo nível em conhecimento de alto nível, enquanto mineração de dados pode ser definida como a extração de padrões ou modelos de dados observados. Segundo Shimabukuru (2004), estima-se que a Mineração de Dados represente de 15% a 25% do processo de KDD.

O termo Interativo indica a atuação do homem para a realização dos processos, sendo ele o responsável por utilizar as ferramentas computacionais para análise e interpretação dos dados. Para obter um resultado satisfatório, é necessário muitas vezes repetir o processo de forma integral ou parcial, ou seja, o processo é iterativo (RABELO, 2007).

A descoberta de conhecimento em base de dados é o processo de extração de conhecimento através de manipulação de dados. Dias (2001) define as seguintes etapas para KDD:

Pré-processamento: Atividades que visam gerar uma representação conveniente para os algoritmos de mineração, a partir da base de dados. Inclui a seleção (automática e/ou manual de atributos relevantes), amostragem, transformações de representação, etc. Esta etapa possui fundamental relevância no processo KDD, e apresenta as seguintes funcionalidades para esta etapa: seleção de dados, limpeza dos dados, codificação dos dados, normalização dos dados, construção de novos atributos e correção de prevalência (RABELO, 2007; GOLDSCHMIDT et al., 2005).

Mineração de dados: Processo de extrair informação válida, previamente desconhecida e de máxima abrangência a partir de grandes bases de dados.

Pós-processamento: Seleção e ordenação das descobertas interessantes, mapeamentos de representação de conhecimento e geração de relatórios. Goldschmidt e Passos (2005) apresentam algumas operações para a realização desta etapa, tais como: simplificação do modelo de conhecimento, transformação do modelo de conhecimento e organização e apresentação dos resultados.

2.7 INTELIGÊNCIA ARTIFICIAL

"Inteligência Artificial é o ramo da ciência da computação que se propõe a elaborar dispositivos [e técnicas] que simulem a capacidade humana de raciocinar, perceber, tomar decisões e resolver problemas, enfim, a capacidade de ser inteligente." (CIRIACO, 2008).

Dentre várias técnicas utilizadas em IA (Inteligência Artificial), as mais utilizadas para o processo de previsão são: RNA (Redes Neurais Artificiais), Lógica Fuzzy e Mineração de Dados.

2.7.1 Mineração de Dados

Conforme Bortoli et. al. (2005, p. 2) Mineração de Dados (Datamining) é

[...] o processo de extrair informação válida, previamente desconhecida e de máxima abrangência a partir de grandes bases de dados, usando-as para efetuar decisões cruciais. O Datamining vai muito além da simples consulta a um banco de dados, no sentido de que permite aos usuários explorar e inferir informação útil a partir dos dados, descobrindo relacionamentos escondidos no banco de dados.

Nas próximas seções são descritas resumidamente as principais tarefas e técnicas de MD.

2.7.2 Tarefas da Mineração de Dados

As tarefas correspondem aos problemas que podem ser tratados pela mineração de dados. As tarefas mais comuns são:

Descrição (*Description*): Segundo Camilo e Silva (2009), é a tarefa utilizada para descrever os padrões e tendências revelados pelos dados. A descrição geralmente oferece uma possível interpretação para os resultados obtidos. A tarefa de descrição é muito utilizada em conjunto com as técnicas de análise exploratória de dados, para comprovar a influência de certas variáveis no resultado obtido.

Classificação (*Classification*): É uma das tarefas mais importantes e populares conhecidas. Tarefa de classificação consiste em construir um modelo de algum tipo que possa ser aplicado a dados não classificados visando categorizá-los em classes. Observando a Figura 2, ela busca uma função que permite associar corretamente cada registro de um banco de dados (x) a um único rótulo categórico chamado de classe (y) (RABELO, 2007).

Exemplo: num levantamento de regiões com probabilidade de existência de mosquito da dengue. Sendo possível criar classes de baixa, médio e alto risco de contaminação.

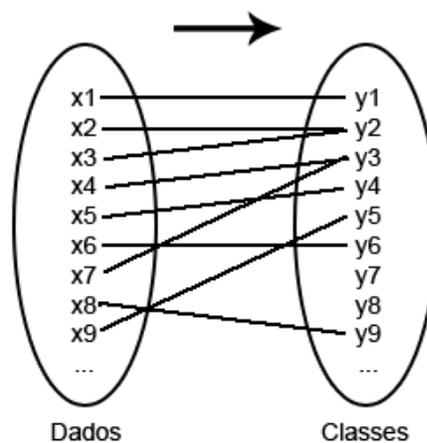


Figura 2 - Associação entre conjunto de dados e classes.
Fonte: Elaborado pelo autor (2013).

Associação (*Association*): Procuram encontrar associações entre conjunto de valores. Um exemplo clássico é determinar quais produtos costumam ser colocados juntos em um carrinho de supermercado. Outra definição seria: "a tarefa de associação pode ser considerada uma tarefa bem definida, determinística e relativamente simples, que não envolve predição da mesma forma que a tarefa de classificação" (FREITAS, 2000 apud DIAS, 2000, p. 10).

Exemplo: determinar quais produtos geralmente são colocados juntos em um carrinho de supermercado.

Agrupamento (*Clustering*): Usado para particionar os registros de uma base de dados em subconjuntos ou *clusters* (Figura 3). Nesta tarefa, não há classes

predefinidas, os registros são agrupados segundo algum critério de semelhança. Exemplos (DIAS, 2001):

- Agrupar clientes por região do país;
- Agrupar clientes com comportamento de compra similar
- Agrupar seções de usuários Web para prever comportamento futuro de usuário.

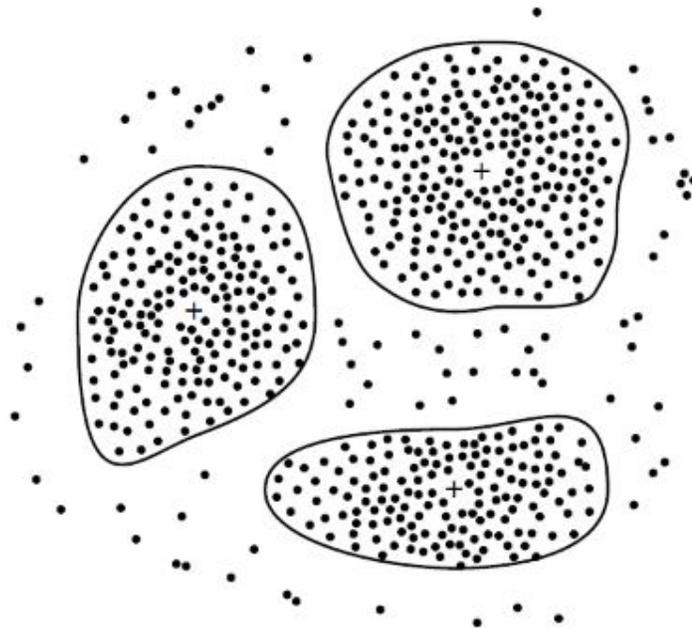


Figura 3 - Registros agrupados em três clusters.
Fonte: Camilo e Silva (2009).

Regressão (*Regression*) ou Estimação (*Estimation*): Esta tarefa é similar à tarefa de classificação, porém é usada quando o registro é identificado por um valor numérico e não categórico. Ela busca por funções que mapeiem os registros de um banco de dados. Exemplos (DIAS, 2001):

- Estimativa da probabilidade de um paciente sobreviver, dado o resultado de um conjunto de diagnóstico de exames;
- Definição do limite do cartão de crédito para cada cliente em um banco;
- Estimativa do número de filhos ou a renda total de uma família;
- Previsão da demanda de um consumidor para um novo produto.

Predição (*Prediction*): É similar às tarefas de classificação e estimação, porém ela visa descobrir o valor futuro de um determinado atributo. Exemplos (CAMILO e SILVA, 2009):

- Predizer o valor de uma ação três meses adiante;
- Predizer o percentual que será aumentado de tráfego na rede se a velocidade aumentar;
- Predizer o vencedor do campeonato baseando-se na comparação das estatísticas dos times.

Alguns métodos de classificação e regressão podem ser usados para predição, com as devidas considerações.

Sumarização (*Summarization*): Consiste em identificar e apresentar, de forma concisa e compreensível, as principais características dos dados em um conjunto de dados (DIAS, 2001).

Exemplo: identificar as características dos candidatos de um concurso público: São pessoas com faixa etária entre X e Y anos, possuem casa própria e nível superior completo (RABELO, 2007).

Exemplos:

- Tabular o significado e desvios padrão para todos os itens de dados;
- Derivar regras de síntese.

Segundo Rabelo (2007), após a seleção de qual tarefa utilizar, precisa-se também escolher o algoritmo, já que para cada tarefa existem diferentes algoritmos, alguns simples e outros mais complexos, como os algoritmos que utilizam redes neurais.

2.7.3 Métodos e técnicas da Mineração de Dados

As tarefas de mineração de dados são desempenhadas por técnicas de mineração de dados e diferentes técnicas servem para diferentes propósitos (RABELO 2007 apud HARRISON, 1998).

Será mostrada somente as técnicas de regressão, foco deste trabalho.

Regressão Linear (*Linear Regression*): As regressões "lineares" quando a relação entre as variáveis de previsão e a resposta seguem um comportamento contínuo (linear). Quando isso ocorre, é possível criar um modelo no qual o valor de y é uma função linear de x . Na Figura 4 pode-se ver um exemplo de uma regressão linear (CAMILO e SILVA, 2009).

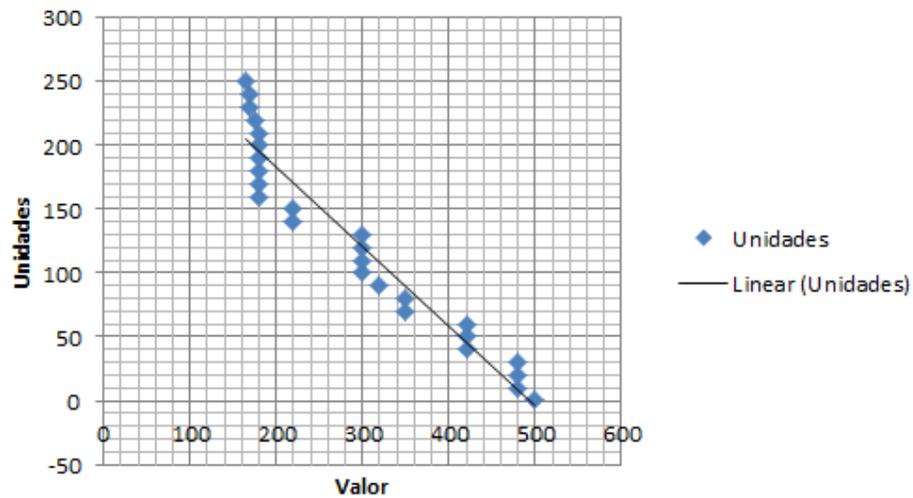


Figura 4 - Regressão Linear.
Fonte: Elaborado pelo autor (2013).

Regressão Não-linear (*Nonlinear Regression*): "Nos modelos de regressão não-linear, a relação entre as variáveis de previsão e a resposta não segue um comportamento linear. Por exemplo, a relação entre as variáveis pode ser modelada como uma função polinomial. [...]" (CAMILO e SILVA, 2009, p. 17).

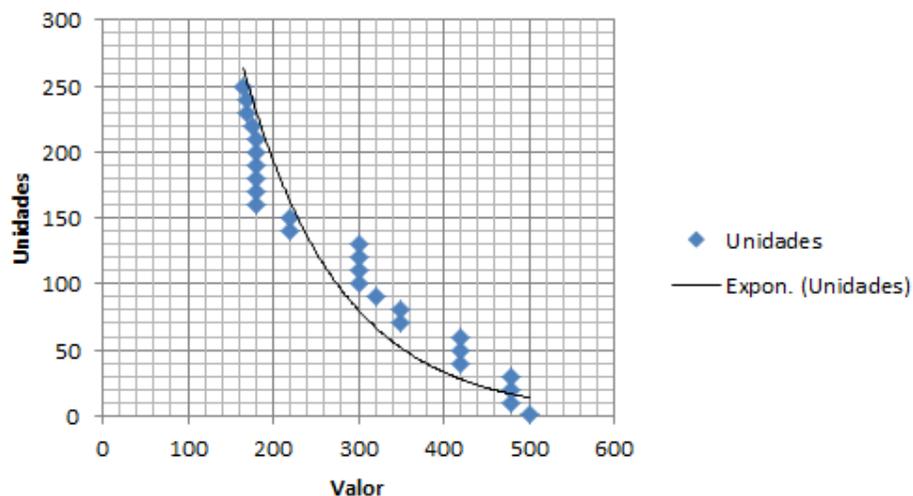


Figura 5 - Regressão Não-linear.
Fonte: Elaborado pelo autor (2013).

3 PROTÓTIPO

Serviços web permitem que organizações trabalhem de forma cooperativa, em forma de terceirização constante de serviços. Fazendo com que essas concentrem-se diretamente em suas atividades principais. Para que isso ocorra, é necessário comunicação entre essas organizações, e isso é feito em forma de serviços: uma organização oferece um serviço enquanto que outras utilizam este, e também disponibilizam seus serviços. Havendo assim, uma troca de atividades.

AOS (Arquitetura Orientada a Serviço) sugere uma estrutura contendo quatro entidades para que essa troca de serviços seja feita de forma correta, conforme Figura 6: aplicação fornecedora, aplicação consumidora, negociação do contrato, monitoração dos serviços.

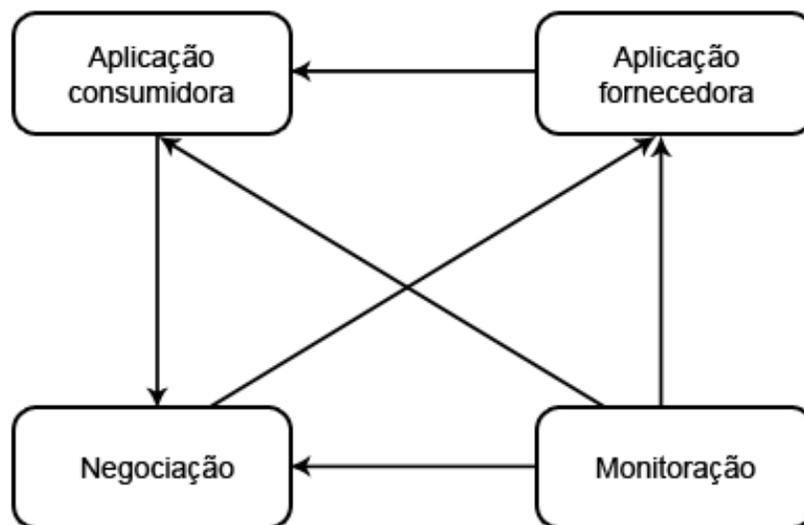


Figura 6 - AOS (Arquitetura Orientada a Serviço).
Fonte: Elaborado pelo autor (2013).

O consumidor inicia uma negociação de contrato com o fornecedor, se ambas partes aceitarem, o contrato estará feito e a troca de serviços poderá ser feita enquanto a entidade de monitoramento ficará analisando cada requisição desses serviços para detectar qualquer comportamento incoerente de acordo com o contrato. Caso necessite de renegociação de contrato a entidade de negociação será chamada novamente.

O propósito do trabalho foi examinar se a técnica de Regressão Linear é adequada e traz os resultados esperados para a aplicação. A monitoração faz a

leitura de execuções anteriores de um arquivo de log, utilizando a técnica de Inteligência Artificial citada acima, e é esperado que se obtenha uma previsão correta ou parcialmente correta das próximas execuções. Como por exemplo: foi decidido entre as entidades que o tempo de resposta do serviço contratado deve ser inferior a 6 segundos, porém o monitor prevê que o contrato será quebrado nas próximas 20 execuções, então é feita a comunicação com o fornecedor para que seja feita uma recontração, ou para que seja tomada alguma providência evitando que isso ocorra (trabalho futuro).

O arquivo de log utilizado possui as seguintes informações: número (contador) da requisição, tempo total da resposta, agente consumidor e agente fornecedor (podendo haver variações e modificações para melhor implementação). De forma simples para facilitar o desenvolvimento do propósito.

4 RESULTADOS

Os resultados são mostrados a seguir, mostrando todo o progresso, incluindo as dificuldades, para se chegar ao esperado.

Primeiramente, para começar com o desenvolvimento foi necessário um arquivo de log contendo, ao menos, uma lista de valores de unidade de tempo (segundos). Para isso, foi necessário desenvolver um pequeno algoritmo utilizando PHP (*Personal Home Page*) para gerar dados aleatórios dentro de uma certa variação, porém como mostrado a seguir na Figura 7, foram instantaneamente descartados.

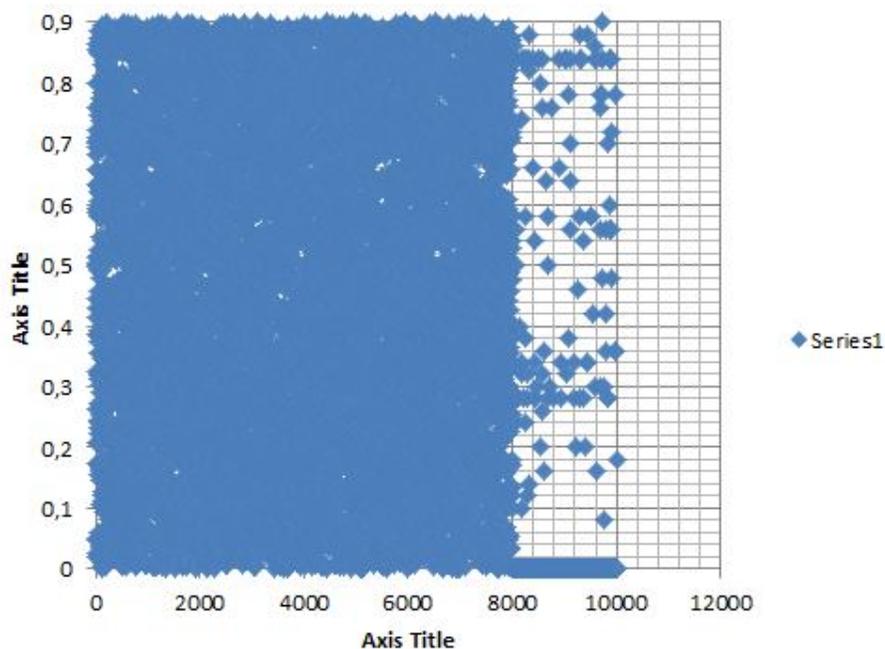


Figura 7 - Gráfico dos dados aleatórios.

Fonte: Elaborado pelo autor (2013).

Em seguida, ainda utilizando PHP, foi gerado os dados de forma que ele fosse incrementando aos poucos e com pequenas variações. Os dados eram aleatórios, porém completamente manipulados, como mostra a Figura 8.

Portanto, era necessário algo mais real, por exemplo a chamada de um serviço de tempo em tempo. Utilizando o ambiente de programação Delphi, foi criado uma pequena aplicação que faria uma chamada do serviço mais simples do Google: a página de pesquisa. Essa aplicação fez a chamada do serviço de um em um segundo durante uma hora e foram obtidos 870 valores, depois todos estes dados

foram copiados para o Microsoft Excel para gerar o gráfico. Os dados eram reais e perfeitos para uso, como mostra a Figura 9.

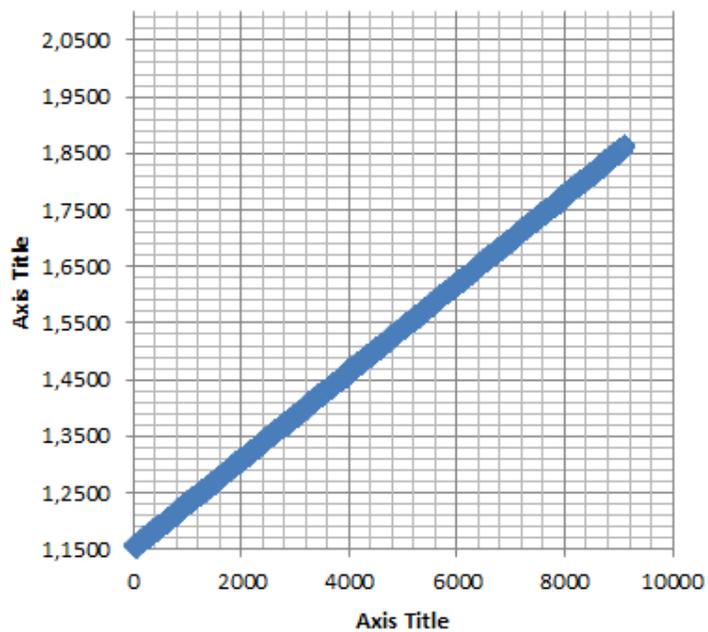


Figura 8 - Gráfico dos dados manipulados.
Fonte: Elaborado pelo autor (2013).

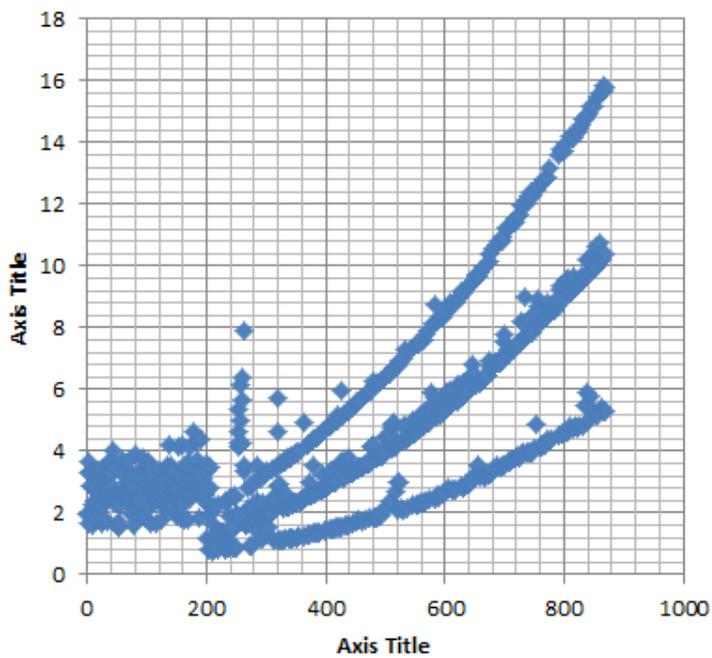


Figura 9 - Gráfico dos dados reais.
Fonte: Elaborado pelo autor (2013).

O próximo passo foi dividir os dados em janelas de 100 (divisões), de modo que tivesse a janela de 0 a 100, 1 a 101, 2 a 102, 3 a 103 e etc. O objetivo era usar as janelas como se fossem os dados de execuções passadas, e as unidades seguintes como execuções futuras (por exemplo: os dados seguintes da janela de 2 a 102 seriam do 103 em diante), que seriam nossa previsão. Feito isso agora era necessário aplicar o algoritmo de Regressão Linear, que é possível ser feito no Excel.

A formula para Regressão Linear:

$$y = ax + b$$

Onde:

- **y**: é a variável de previsão, a linha vertical no gráfico.
- **a**: é o resultado da formula de inclinação, que pode ser obtida no Excel utilizando a função INCLINAÇÃO (SLOPE).
- **x**: é a unidade de tempo, a linha horizontal no gráfico.
- **b**: é o resultado da formula de intercepção, que pode ser obtida no Excel utilizando a função INTERCEPÇÃO (INTERCEPT).

Mas o valor de **y** já era conhecido, portanto era necessário encontrar o valor de **x**, invertendo a equação ficará:

$$x = (-b+y)/a$$

A formula de inclinação é:

$$\frac{n \sum(xy) - \sum x \sum y}{n \sum x^2 - (\sum x)^2}$$

Onde:

- **x**: é a unidade de tempo, a linha horizontal no gráfico.
- **y**: os valores de fato (dados obtidos), a linha vertical no gráfico.

A formula de intercepção é:

$$\frac{\sum x^2 \sum y - \sum(xy) \sum x}{n \sum x^2 - (\sum x)^2}$$

Onde:

- **x**: é a unidade de tempo, a linha horizontal no gráfico.
- **y**: os valores de fato (dados obtidos), a linha vertical no gráfico.

Conforme o andamento, as janelas foram aumentadas para 300 (1 a 300, 2 a 302, 3 a 303, etc.), pois as previsões não estavam muito bem em virtude da pouca quantidade de dados anteriores, e os valores totais foram diminuídos para 700. Um exemplo de como estava pode ser visto na Figura 10, onde o TR (tempo de resposta - no máximo, conforme o consumidor e fornecedor entraram em acordo) é de 5 segundos, a primeira ocorrência do valor de 5 segundos ou mais teria chegado logo na unidade de tempo 425, e nas 5 tentativas as taxas de erros foram superiores a 200 unidades de tempo.

Janela	a	b	Previsão	Erro
120-420	0,007805018	0,863017311	531	202
121-421	0,00769393	0,891001523	535	206
122-422	0,007665923	0,900716158	535	206
123-423	0,007809359	0,872310749	529	200
124-424	0,007696444	0,900925152	533	204

Figura 10 - Exemplo do algoritmo em execução.
Fonte: Elaborado pelo autor (2013).

Porém, estava complicado continuar no Excel, pois seria necessário fazer várias verificações para saber qual a próxima unidade de tempo que "estouraria" o tempo limite a partir da atual janela. Seria necessário criar vários itens de "primeira ocorrência", um para cada janela praticamente. Portanto, foi tudo refeito numa aplicação PHP, onde poderia ser feito tudo de maneira automática, e os resultados finais podem ser visualizados a seguir na Tabela 1.

Tabela 1 - Resultados obtidos a partir de uma TR de 8 segundos.

Janela	Previsão	Correto	Dif. acerto	Prob. acerto
0->300 u.t.	-8230 u.t.	481 u.t. (8.12 s)	-8711 u.t.	-5.84%
1->301 u.t.	-10455 u.t.	481 u.t. (8.12 s)	-10936 u.t.	-4.60%
2->302 u.t.	-9994 u.t.	481 u.t. (8.12 s)	-10475 u.t.	-4.81%
3->303 u.t.	-10930 u.t.	481 u.t. (8.12 s)	-11411 u.t.	-4.40%
4->304 u.t.	-10802 u.t.	481 u.t. (8.12 s)	-11283 u.t.	-4.45%

5->305 u.t.	-19384 u.t.	481 u.t. (8.12 s)	-19865 u.t.	-2.48%
6->306 u.t.	-18426 u.t.	481 u.t. (8.12 s)	-18907 u.t.	-2.61%
7->307 u.t.	-21499 u.t.	481 u.t. (8.12 s)	-21980 u.t.	-2.24%
8->308 u.t.	-33740 u.t.	481 u.t. (8.12 s)	-34221 u.t.	-1.43%
9->309 u.t.	-121035 u.t.	481 u.t. (8.12 s)	-121516 u.t.	-0.40%
10->310 u.t.	90258 u.t.	481 u.t. (8.12 s)	89777 u.t.	0.53%
11->311 u.t.	19873231 u.t.	481 u.t. (8.12 s)	19872750 u.t.	0.00%
12->312 u.t.	32821 u.t.	481 u.t. (8.12 s)	32340 u.t.	1.47%
13->313 u.t.	41335 u.t.	481 u.t. (8.12 s)	40854 u.t.	1.16%
14->314 u.t.	36879 u.t.	481 u.t. (8.12 s)	36398 u.t.	1.30%
15->315 u.t.	32389 u.t.	481 u.t. (8.12 s)	31908 u.t.	1.49%
16->316 u.t.	39657 u.t.	481 u.t. (8.12 s)	39176 u.t.	1.21%
17->317 u.t.	18877 u.t.	481 u.t. (8.12 s)	18396 u.t.	2.55%
18->318 u.t.	24462 u.t.	481 u.t. (8.12 s)	23981 u.t.	1.97%
19->319 u.t.	13848 u.t.	481 u.t. (8.12 s)	13367 u.t.	3.47%
20->320 u.t.	17179 u.t.	481 u.t. (8.12 s)	16698 u.t.	2.80%
21->321 u.t.	10779 u.t.	481 u.t. (8.12 s)	10298 u.t.	4.46%
22->322 u.t.	9617 u.t.	481 u.t. (8.12 s)	9136 u.t.	5.00%
23->323 u.t.	11003 u.t.	481 u.t. (8.12 s)	10522 u.t.	4.37%
24->324 u.t.	8916 u.t.	481 u.t. (8.12 s)	8435 u.t.	5.39%
25->325 u.t.	7627 u.t.	481 u.t. (8.12 s)	7146 u.t.	6.31%
26->326 u.t.	5799 u.t.	481 u.t. (8.12 s)	5318 u.t.	8.29%
27->327 u.t.	6650 u.t.	481 u.t. (8.12 s)	6169 u.t.	7.23%
28->328 u.t.	6280 u.t.	481 u.t. (8.12 s)	5799 u.t.	7.66%
29->329 u.t.	5133 u.t.	481 u.t. (8.12 s)	4652 u.t.	9.37%
30->330 u.t.	4827 u.t.	481 u.t. (8.12 s)	4346 u.t.	9.96%
31->331 u.t.	4680 u.t.	481 u.t. (8.12 s)	4199 u.t.	10.28%
32->332 u.t.	4371 u.t.	481 u.t. (8.12 s)	3890 u.t.	11.00%
33->333 u.t.	4596 u.t.	481 u.t. (8.12 s)	4115 u.t.	10.47%
34->334 u.t.	4263 u.t.	481 u.t. (8.12 s)	3782 u.t.	11.28%
35->335 u.t.	3845 u.t.	481 u.t. (8.12 s)	3364 u.t.	12.51%
36->336 u.t.	3559 u.t.	481 u.t. (8.12 s)	3078 u.t.	13.52%
37->337 u.t.	3626 u.t.	481 u.t. (8.12 s)	3145 u.t.	13.27%
38->338 u.t.	3098 u.t.	481 u.t. (8.12 s)	2617 u.t.	15.53%
39->339 u.t.	2928 u.t.	481 u.t. (8.12 s)	2447 u.t.	16.43%
40->340 u.t.	2942 u.t.	481 u.t. (8.12 s)	2461 u.t.	16.35%
41->341 u.t.	2816 u.t.	481 u.t. (8.12 s)	2335 u.t.	17.08%
42->342 u.t.	2702 u.t.	481 u.t. (8.12 s)	2221 u.t.	17.80%
43->343 u.t.	2598 u.t.	481 u.t. (8.12 s)	2117 u.t.	18.51%
44->344 u.t.	2405 u.t.	481 u.t. (8.12 s)	1924 u.t.	20.00%
45->345 u.t.	2480 u.t.	481 u.t. (8.12 s)	1999 u.t.	19.40%
46->346 u.t.	2462 u.t.	481 u.t. (8.12 s)	1981 u.t.	19.54%
47->347 u.t.	2415 u.t.	481 u.t. (8.12 s)	1934 u.t.	19.92%
48->348 u.t.	2367 u.t.	481 u.t. (8.12 s)	1886 u.t.	20.32%
49->349 u.t.	2316 u.t.	481 u.t. (8.12 s)	1835 u.t.	20.77%
50->350 u.t.	2200 u.t.	481 u.t. (8.12 s)	1719 u.t.	21.86%
51->351 u.t.	2242 u.t.	481 u.t. (8.12 s)	1761 u.t.	21.45%
52->352 u.t.	2129 u.t.	481 u.t. (8.12 s)	1648 u.t.	22.59%

53->353 u.t.	2106 u.t.	481 u.t. (8.12 s)	1625 u.t.	22.84%
54->354 u.t.	2081 u.t.	481 u.t. (8.12 s)	1600 u.t.	23.11%
55->355 u.t.	2029 u.t.	481 u.t. (8.12 s)	1548 u.t.	23.71%
56->356 u.t.	1973 u.t.	481 u.t. (8.12 s)	1492 u.t.	24.38%
57->357 u.t.	1974 u.t.	481 u.t. (8.12 s)	1493 u.t.	24.37%
58->358 u.t.	1958 u.t.	481 u.t. (8.12 s)	1477 u.t.	24.57%
59->359 u.t.	1857 u.t.	481 u.t. (8.12 s)	1376 u.t.	25.90%
60->360 u.t.	1905 u.t.	481 u.t. (8.12 s)	1424 u.t.	25.25%
61->361 u.t.	1826 u.t.	481 u.t. (8.12 s)	1345 u.t.	26.34%
62->362 u.t.	1826 u.t.	481 u.t. (8.12 s)	1345 u.t.	26.34%
63->363 u.t.	1775 u.t.	481 u.t. (8.12 s)	1294 u.t.	27.10%
64->364 u.t.	1776 u.t.	481 u.t. (8.12 s)	1295 u.t.	27.08%
65->365 u.t.	1728 u.t.	481 u.t. (8.12 s)	1247 u.t.	27.84%
66->366 u.t.	1635 u.t.	481 u.t. (8.12 s)	1154 u.t.	29.42%
67->367 u.t.	1652 u.t.	481 u.t. (8.12 s)	1171 u.t.	29.12%
68->368 u.t.	1633 u.t.	481 u.t. (8.12 s)	1152 u.t.	29.45%
69->369 u.t.	1633 u.t.	481 u.t. (8.12 s)	1152 u.t.	29.45%
70->370 u.t.	1589 u.t.	481 u.t. (8.12 s)	1108 u.t.	30.27%
71->371 u.t.	1508 u.t.	481 u.t. (8.12 s)	1027 u.t.	31.90%
72->372 u.t.	1498 u.t.	481 u.t. (8.12 s)	1017 u.t.	32.11%
73->373 u.t.	1485 u.t.	481 u.t. (8.12 s)	1004 u.t.	32.39%
74->374 u.t.	1453 u.t.	481 u.t. (8.12 s)	972 u.t.	33.10%
75->375 u.t.	1391 u.t.	481 u.t. (8.12 s)	910 u.t.	34.58%
76->376 u.t.	1366 u.t.	481 u.t. (8.12 s)	885 u.t.	35.21%
77->377 u.t.	1345 u.t.	481 u.t. (8.12 s)	864 u.t.	35.76%
78->378 u.t.	1296 u.t.	481 u.t. (8.12 s)	815 u.t.	37.11%
79->379 u.t.	1309 u.t.	481 u.t. (8.12 s)	828 u.t.	36.75%
80->380 u.t.	1252 u.t.	481 u.t. (8.12 s)	771 u.t.	38.42%
81->381 u.t.	1226 u.t.	481 u.t. (8.12 s)	745 u.t.	39.23%
82->382 u.t.	1238 u.t.	481 u.t. (8.12 s)	757 u.t.	38.85%
83->383 u.t.	1222 u.t.	481 u.t. (8.12 s)	741 u.t.	39.36%
84->384 u.t.	1171 u.t.	481 u.t. (8.12 s)	690 u.t.	41.08%
85->385 u.t.	1166 u.t.	481 u.t. (8.12 s)	685 u.t.	41.25%
86->386 u.t.	1155 u.t.	481 u.t. (8.12 s)	674 u.t.	41.65%
87->387 u.t.	1117 u.t.	481 u.t. (8.12 s)	636 u.t.	43.06%
88->388 u.t.	1128 u.t.	481 u.t. (8.12 s)	647 u.t.	42.64%
89->389 u.t.	1113 u.t.	481 u.t. (8.12 s)	632 u.t.	43.22%
90->390 u.t.	1111 u.t.	481 u.t. (8.12 s)	630 u.t.	43.29%
91->391 u.t.	1101 u.t.	481 u.t. (8.12 s)	620 u.t.	43.69%
92->392 u.t.	1055 u.t.	481 u.t. (8.12 s)	574 u.t.	45.59%
93->393 u.t.	1064 u.t.	481 u.t. (8.12 s)	583 u.t.	45.21%
94->394 u.t.	1052 u.t.	481 u.t. (8.12 s)	571 u.t.	45.72%
95->395 u.t.	1044 u.t.	481 u.t. (8.12 s)	563 u.t.	46.07%
96->396 u.t.	1036 u.t.	481 u.t. (8.12 s)	555 u.t.	46.43%
97->397 u.t.	1008 u.t.	481 u.t. (8.12 s)	527 u.t.	47.72%
98->398 u.t.	997 u.t.	481 u.t. (8.12 s)	516 u.t.	48.24%
99->399 u.t.	1004 u.t.	481 u.t. (8.12 s)	523 u.t.	47.91%
100->400 u.t.	993 u.t.	481 u.t. (8.12 s)	512 u.t.	48.44%

101->401 u.t.	962 u.t.	481 u.t. (8.12 s)	481 u.t.	50.00%
102->402 u.t.	962 u.t.	481 u.t. (8.12 s)	481 u.t.	50.00%
103->403 u.t.	955 u.t.	481 u.t. (8.12 s)	474 u.t.	50.37%
104->404 u.t.	957 u.t.	481 u.t. (8.12 s)	476 u.t.	50.26%
105->405 u.t.	950 u.t.	481 u.t. (8.12 s)	469 u.t.	50.63%
106->406 u.t.	960 u.t.	481 u.t. (8.12 s)	479 u.t.	50.10%
107->407 u.t.	933 u.t.	481 u.t. (8.12 s)	452 u.t.	51.55%
108->408 u.t.	924 u.t.	481 u.t. (8.12 s)	443 u.t.	52.06%
109->409 u.t.	935 u.t.	481 u.t. (8.12 s)	454 u.t.	51.44%
110->410 u.t.	935 u.t.	481 u.t. (8.12 s)	454 u.t.	51.44%
111->411 u.t.	932 u.t.	481 u.t. (8.12 s)	451 u.t.	51.61%
112->412 u.t.	930 u.t.	481 u.t. (8.12 s)	449 u.t.	51.72%
113->413 u.t.	929 u.t.	481 u.t. (8.12 s)	448 u.t.	51.78%
114->414 u.t.	926 u.t.	481 u.t. (8.12 s)	445 u.t.	51.94%
115->415 u.t.	915 u.t.	481 u.t. (8.12 s)	434 u.t.	52.57%
116->416 u.t.	926 u.t.	481 u.t. (8.12 s)	445 u.t.	51.94%
117->417 u.t.	929 u.t.	481 u.t. (8.12 s)	448 u.t.	51.78%
118->418 u.t.	915 u.t.	481 u.t. (8.12 s)	434 u.t.	52.57%
119->419 u.t.	925 u.t.	481 u.t. (8.12 s)	444 u.t.	52.00%
120->420 u.t.	914 u.t.	481 u.t. (8.12 s)	433 u.t.	52.63%
121->421 u.t.	924 u.t.	481 u.t. (8.12 s)	443 u.t.	52.06%
122->422 u.t.	926 u.t.	481 u.t. (8.12 s)	445 u.t.	51.94%
123->423 u.t.	913 u.t.	481 u.t. (8.12 s)	432 u.t.	52.68%
124->424 u.t.	922 u.t.	481 u.t. (8.12 s)	441 u.t.	52.17%
125->425 u.t.	909 u.t.	481 u.t. (8.12 s)	428 u.t.	52.92%
126->426 u.t.	924 u.t.	481 u.t. (8.12 s)	443 u.t.	52.06%
127->427 u.t.	926 u.t.	481 u.t. (8.12 s)	445 u.t.	51.94%
128->428 u.t.	928 u.t.	481 u.t. (8.12 s)	447 u.t.	51.83%
129->429 u.t.	915 u.t.	481 u.t. (8.12 s)	434 u.t.	52.57%
130->430 u.t.	914 u.t.	481 u.t. (8.12 s)	433 u.t.	52.63%
131->431 u.t.	925 u.t.	481 u.t. (8.12 s)	444 u.t.	52.00%
132->432 u.t.	930 u.t.	481 u.t. (8.12 s)	449 u.t.	51.72%
133->433 u.t.	910 u.t.	481 u.t. (8.12 s)	429 u.t.	52.86%
134->434 u.t.	912 u.t.	481 u.t. (8.12 s)	431 u.t.	52.74%
135->435 u.t.	928 u.t.	481 u.t. (8.12 s)	447 u.t.	51.83%
136->436 u.t.	930 u.t.	481 u.t. (8.12 s)	449 u.t.	51.72%
137->437 u.t.	932 u.t.	481 u.t. (8.12 s)	451 u.t.	51.61%
138->438 u.t.	929 u.t.	481 u.t. (8.12 s)	448 u.t.	51.78%
139->439 u.t.	929 u.t.	481 u.t. (8.12 s)	448 u.t.	51.78%
140->440 u.t.	934 u.t.	481 u.t. (8.12 s)	453 u.t.	51.50%
141->441 u.t.	937 u.t.	481 u.t. (8.12 s)	456 u.t.	51.33%
142->442 u.t.	939 u.t.	481 u.t. (8.12 s)	458 u.t.	51.22%
143->443 u.t.	935 u.t.	481 u.t. (8.12 s)	454 u.t.	51.44%
144->444 u.t.	924 u.t.	481 u.t. (8.12 s)	443 u.t.	52.06%
145->445 u.t.	924 u.t.	481 u.t. (8.12 s)	443 u.t.	52.06%
146->446 u.t.	940 u.t.	481 u.t. (8.12 s)	459 u.t.	51.17%
147->447 u.t.	936 u.t.	481 u.t. (8.12 s)	455 u.t.	51.39%
148->448 u.t.	942 u.t.	481 u.t. (8.12 s)	461 u.t.	51.06%

149->449 u.t.	938 u.t.	481 u.t. (8.12 s)	457 u.t.	51.28%
150->450 u.t.	921 u.t.	481 u.t. (8.12 s)	440 u.t.	52.23%
151->451 u.t.	935 u.t.	481 u.t. (8.12 s)	454 u.t.	51.44%
152->452 u.t.	941 u.t.	481 u.t. (8.12 s)	460 u.t.	51.12%
153->453 u.t.	929 u.t.	481 u.t. (8.12 s)	448 u.t.	51.78%
154->454 u.t.	900 u.t.	481 u.t. (8.12 s)	419 u.t.	53.44%
155->455 u.t.	897 u.t.	481 u.t. (8.12 s)	416 u.t.	53.62%
156->456 u.t.	873 u.t.	481 u.t. (8.12 s)	392 u.t.	55.10%
157->457 u.t.	861 u.t.	481 u.t. (8.12 s)	380 u.t.	55.87%
158->458 u.t.	856 u.t.	481 u.t. (8.12 s)	375 u.t.	56.19%
159->459 u.t.	844 u.t.	481 u.t. (8.12 s)	363 u.t.	56.99%
160->460 u.t.	816 u.t.	481 u.t. (8.12 s)	335 u.t.	58.95%
161->461 u.t.	807 u.t.	481 u.t. (8.12 s)	326 u.t.	59.60%
162->462 u.t.	805 u.t.	481 u.t. (8.12 s)	324 u.t.	59.75%
163->463 u.t.	790 u.t.	481 u.t. (8.12 s)	309 u.t.	60.89%
164->464 u.t.	781 u.t.	481 u.t. (8.12 s)	300 u.t.	61.59%
165->465 u.t.	776 u.t.	481 u.t. (8.12 s)	295 u.t.	61.98%
166->466 u.t.	776 u.t.	481 u.t. (8.12 s)	295 u.t.	61.98%
167->467 u.t.	767 u.t.	481 u.t. (8.12 s)	286 u.t.	62.71%
168->468 u.t.	766 u.t.	481 u.t. (8.12 s)	285 u.t.	62.79%
169->469 u.t.	775 u.t.	481 u.t. (8.12 s)	294 u.t.	62.06%
170->470 u.t.	772 u.t.	481 u.t. (8.12 s)	291 u.t.	62.31%
171->471 u.t.	762 u.t.	481 u.t. (8.12 s)	281 u.t.	63.12%
172->472 u.t.	760 u.t.	481 u.t. (8.12 s)	279 u.t.	63.29%
173->473 u.t.	770 u.t.	481 u.t. (8.12 s)	289 u.t.	62.47%
174->474 u.t.	770 u.t.	481 u.t. (8.12 s)	289 u.t.	62.47%
175->475 u.t.	767 u.t.	481 u.t. (8.12 s)	286 u.t.	62.71%
176->476 u.t.	766 u.t.	481 u.t. (8.12 s)	285 u.t.	62.79%
177->477 u.t.	764 u.t.	481 u.t. (8.12 s)	283 u.t.	62.96%
178->478 u.t.	764 u.t.	481 u.t. (8.12 s)	283 u.t.	62.96%
179->479 u.t.	760 u.t.	481 u.t. (8.12 s)	279 u.t.	63.29%
180->480 u.t.	759 u.t.	481 u.t. (8.12 s)	278 u.t.	63.37%
181->481 u.t.	750 u.t.	483 u.t. (8.75 s)	267 u.t.	64.40%
182->482 u.t.	758 u.t.	483 u.t. (8.75 s)	275 u.t.	63.72%
183->483 u.t.	748 u.t.	487 u.t. (8.189 s)	261 u.t.	65.11%
184->484 u.t.	746 u.t.	487 u.t. (8.189 s)	259 u.t.	65.28%
185->485 u.t.	750 u.t.	487 u.t. (8.189 s)	263 u.t.	64.93%
186->486 u.t.	749 u.t.	487 u.t. (8.189 s)	262 u.t.	65.02%
187->487 u.t.	742 u.t.	490 u.t. (8.288 s)	252 u.t.	66.04%
188->488 u.t.	741 u.t.	490 u.t. (8.288 s)	251 u.t.	66.13%
189->489 u.t.	748 u.t.	490 u.t. (8.288 s)	258 u.t.	65.51%
190->490 u.t.	740 u.t.	495 u.t. (8.305 s)	245 u.t.	66.89%
191->491 u.t.	745 u.t.	495 u.t. (8.305 s)	250 u.t.	66.44%
192->492 u.t.	747 u.t.	495 u.t. (8.305 s)	252 u.t.	66.27%
193->493 u.t.	744 u.t.	495 u.t. (8.305 s)	249 u.t.	66.53%
194->494 u.t.	743 u.t.	495 u.t. (8.305 s)	248 u.t.	66.62%
195->495 u.t.	737 u.t.	499 u.t. (8.431 s)	238 u.t.	67.71%
196->496 u.t.	736 u.t.	499 u.t. (8.431 s)	237 u.t.	67.80%

197->497 u.t.	743 u.t.	499 u.t. (8.431 s)	244 u.t.	67.16%
198->498 u.t.	744 u.t.	499 u.t. (8.431 s)	245 u.t.	67.07%
199->499 u.t.	736 u.t.	502 u.t. (8.589 s)	234 u.t.	68.21%
200->500 u.t.	740 u.t.	502 u.t. (8.589 s)	238 u.t.	67.84%
201->501 u.t.	742 u.t.	502 u.t. (8.589 s)	240 u.t.	67.65%
202->502 u.t.	734 u.t.	509 u.t. (8.797 s)	225 u.t.	69.35%
203->503 u.t.	730 u.t.	509 u.t. (8.797 s)	221 u.t.	69.73%
204->504 u.t.	730 u.t.	509 u.t. (8.797 s)	221 u.t.	69.73%
205->505 u.t.	736 u.t.	509 u.t. (8.797 s)	227 u.t.	69.16%
206->506 u.t.	736 u.t.	509 u.t. (8.797 s)	227 u.t.	69.16%
207->507 u.t.	736 u.t.	509 u.t. (8.797 s)	227 u.t.	69.16%
208->508 u.t.	736 u.t.	509 u.t. (8.797 s)	227 u.t.	69.16%
209->509 u.t.	728 u.t.	513 u.t. (8.718 s)	215 u.t.	70.47%
210->510 u.t.	727 u.t.	513 u.t. (8.718 s)	214 u.t.	70.56%
211->511 u.t.	733 u.t.	513 u.t. (8.718 s)	220 u.t.	69.99%
212->512 u.t.	730 u.t.	513 u.t. (8.718 s)	217 u.t.	70.27%
213->513 u.t.	722 u.t.	517 u.t. (8.827 s)	205 u.t.	71.61%
214->514 u.t.	728 u.t.	517 u.t. (8.827 s)	211 u.t.	71.02%
215->515 u.t.	730 u.t.	517 u.t. (8.827 s)	213 u.t.	70.82%
216->516 u.t.	730 u.t.	517 u.t. (8.827 s)	213 u.t.	70.82%
217->517 u.t.	721 u.t.	524 u.t. (8.988 s)	197 u.t.	72.68%
218->518 u.t.	726 u.t.	524 u.t. (8.988 s)	202 u.t.	72.18%
219->519 u.t.	724 u.t.	524 u.t. (8.988 s)	200 u.t.	72.38%
220->520 u.t.	718 u.t.	524 u.t. (8.988 s)	194 u.t.	72.98%
221->521 u.t.	713 u.t.	524 u.t. (8.988 s)	189 u.t.	73.49%
222->522 u.t.	715 u.t.	524 u.t. (8.988 s)	191 u.t.	73.29%
223->523 u.t.	714 u.t.	524 u.t. (8.988 s)	190 u.t.	73.39%
224->524 u.t.	704 u.t.	528 u.t. (9.149 s)	176 u.t.	75.00%
225->525 u.t.	705 u.t.	528 u.t. (9.149 s)	177 u.t.	74.89%
226->526 u.t.	709 u.t.	528 u.t. (9.149 s)	181 u.t.	74.47%
227->527 u.t.	708 u.t.	528 u.t. (9.149 s)	180 u.t.	74.58%
228->528 u.t.	703 u.t.	532 u.t. (9.118 s)	171 u.t.	75.68%
229->529 u.t.	702 u.t.	532 u.t. (9.118 s)	170 u.t.	75.78%
230->530 u.t.	706 u.t.	532 u.t. (9.118 s)	174 u.t.	75.35%
231->531 u.t.	708 u.t.	532 u.t. (9.118 s)	176 u.t.	75.14%
232->532 u.t.	699 u.t.	535 u.t. (9.204 s)	164 u.t.	76.54%
233->533 u.t.	705 u.t.	535 u.t. (9.204 s)	170 u.t.	75.89%
234->534 u.t.	706 u.t.	535 u.t. (9.204 s)	171 u.t.	75.78%
235->535 u.t.	700 u.t.	537 u.t. (9.307 s)	163 u.t.	76.71%
236->536 u.t.	706 u.t.	537 u.t. (9.307 s)	169 u.t.	76.06%
237->537 u.t.	697 u.t.	542 u.t. (9.386 s)	155 u.t.	77.76%
238->538 u.t.	698 u.t.	542 u.t. (9.386 s)	156 u.t.	77.65%
239->539 u.t.	697 u.t.	542 u.t. (9.386 s)	155 u.t.	77.76%
240->540 u.t.	701 u.t.	542 u.t. (9.386 s)	159 u.t.	77.32%
241->541 u.t.	702 u.t.	542 u.t. (9.386 s)	160 u.t.	77.21%
242->542 u.t.	694 u.t.	549 u.t. (9.558 s)	145 u.t.	79.11%
243->543 u.t.	695 u.t.	549 u.t. (9.558 s)	146 u.t.	78.99%
244->544 u.t.	699 u.t.	549 u.t. (9.558 s)	150 u.t.	78.54%

245->545 u.t.	700 u.t.	549 u.t. (9.558 s)	151 u.t.	78.43%
246->546 u.t.	699 u.t.	549 u.t. (9.558 s)	150 u.t.	78.54%
247->547 u.t.	698 u.t.	549 u.t. (9.558 s)	149 u.t.	78.65%
248->548 u.t.	697 u.t.	549 u.t. (9.558 s)	148 u.t.	78.77%
249->549 u.t.	691 u.t.	551 u.t. (9.643 s)	140 u.t.	79.74%
250->550 u.t.	695 u.t.	551 u.t. (9.643 s)	144 u.t.	79.28%
251->551 u.t.	690 u.t.	554 u.t. (9.744 s)	136 u.t.	80.29%
252->552 u.t.	695 u.t.	554 u.t. (9.744 s)	141 u.t.	79.71%
253->553 u.t.	693 u.t.	554 u.t. (9.744 s)	139 u.t.	79.94%
254->554 u.t.	689 u.t.	556 u.t. (9.676 s)	133 u.t.	80.70%
255->555 u.t.	691 u.t.	556 u.t. (9.676 s)	135 u.t.	80.46%
256->556 u.t.	687 u.t.	559 u.t. (9.787 s)	128 u.t.	81.37%
257->557 u.t.	692 u.t.	559 u.t. (9.787 s)	133 u.t.	80.78%
258->558 u.t.	692 u.t.	559 u.t. (9.787 s)	133 u.t.	80.78%
259->559 u.t.	686 u.t.	564 u.t. (9.948 s)	122 u.t.	82.22%
260->560 u.t.	691 u.t.	564 u.t. (9.948 s)	127 u.t.	81.62%
261->561 u.t.	692 u.t.	564 u.t. (9.948 s)	128 u.t.	81.50%
262->562 u.t.	692 u.t.	564 u.t. (9.948 s)	128 u.t.	81.50%
263->563 u.t.	689 u.t.	564 u.t. (9.948 s)	125 u.t.	81.86%
264->564 u.t.	685 u.t.	567 u.t. (9.994 s)	118 u.t.	82.77%
265->565 u.t.	690 u.t.	567 u.t. (9.994 s)	123 u.t.	82.17%
266->566 u.t.	690 u.t.	567 u.t. (9.994 s)	123 u.t.	82.17%
267->567 u.t.	684 u.t.	573 u.t. (10.117 s)	111 u.t.	83.77%
268->568 u.t.	690 u.t.	573 u.t. (10.117 s)	117 u.t.	83.04%
269->569 u.t.	690 u.t.	573 u.t. (10.117 s)	117 u.t.	83.04%
270->570 u.t.	688 u.t.	573 u.t. (10.117 s)	115 u.t.	83.28%
271->571 u.t.	689 u.t.	573 u.t. (10.117 s)	116 u.t.	83.16%
272->572 u.t.	688 u.t.	573 u.t. (10.117 s)	115 u.t.	83.28%
273->573 u.t.	682 u.t.	576 u.t. (10.39 s)	106 u.t.	84.46%
274->574 u.t.	682 u.t.	576 u.t. (10.39 s)	106 u.t.	84.46%
275->575 u.t.	688 u.t.	576 u.t. (10.39 s)	112 u.t.	83.72%
276->576 u.t.	682 u.t.	580 u.t. (10.567 s)	102 u.t.	85.04%
277->577 u.t.	687 u.t.	580 u.t. (10.567 s)	107 u.t.	84.43%
278->578 u.t.	685 u.t.	580 u.t. (10.567 s)	105 u.t.	84.67%
279->579 u.t.	684 u.t.	580 u.t. (10.567 s)	104 u.t.	84.80%
280->580 u.t.	679 u.t.	587 u.t. (10.712 s)	92 u.t.	86.45%
281->581 u.t.	682 u.t.	587 u.t. (10.712 s)	95 u.t.	86.07%
282->582 u.t.	683 u.t.	587 u.t. (10.712 s)	96 u.t.	85.94%
283->583 u.t.	683 u.t.	587 u.t. (10.712 s)	96 u.t.	85.94%
284->584 u.t.	683 u.t.	587 u.t. (10.712 s)	96 u.t.	85.94%
285->585 u.t.	681 u.t.	587 u.t. (10.712 s)	94 u.t.	86.20%
286->586 u.t.	682 u.t.	587 u.t. (10.712 s)	95 u.t.	86.07%
287->587 u.t.	676 u.t.	591 u.t. (10.837 s)	85 u.t.	87.43%
288->588 u.t.	679 u.t.	591 u.t. (10.837 s)	88 u.t.	87.04%
289->589 u.t.	681 u.t.	591 u.t. (10.837 s)	90 u.t.	86.78%
290->590 u.t.	679 u.t.	591 u.t. (10.837 s)	88 u.t.	87.04%
291->591 u.t.	674 u.t.	596 u.t. (10.792 s)	78 u.t.	88.43%
292->592 u.t.	679 u.t.	596 u.t. (10.792 s)	83 u.t.	87.78%

293->593 u.t.	679 u.t.	596 u.t. (10.792 s)	83 u.t.	87.78%
294->594 u.t.	679 u.t.	596 u.t. (10.792 s)	83 u.t.	87.78%
295->595 u.t.	679 u.t.	596 u.t. (10.792 s)	83 u.t.	87.78%
296->596 u.t.	672 u.t.	598 u.t. (10.955 s)	74 u.t.	88.99%
297->597 u.t.	676 u.t.	598 u.t. (10.955 s)	78 u.t.	88.46%
298->598 u.t.	672 u.t.	604 u.t. (11.214 s)	68 u.t.	89.88%
299->599 u.t.	672 u.t.	604 u.t. (11.214 s)	68 u.t.	89.88%
300->600 u.t.	676 u.t.	604 u.t. (11.214 s)	72 u.t.	89.35%
301->601 u.t.	675 u.t.	604 u.t. (11.214 s)	71 u.t.	89.48%
302->602 u.t.	674 u.t.	604 u.t. (11.214 s)	70 u.t.	89.61%
303->603 u.t.	675 u.t.	604 u.t. (11.214 s)	71 u.t.	89.48%
304->604 u.t.	669 u.t.	607 u.t. (11.232 s)	62 u.t.	90.73%
305->605 u.t.	674 u.t.	607 u.t. (11.232 s)	67 u.t.	90.06%
306->606 u.t.	672 u.t.	607 u.t. (11.232 s)	65 u.t.	90.33%
307->607 u.t.	668 u.t.	609 u.t. (11.28 s)	59 u.t.	91.17%
308->608 u.t.	672 u.t.	609 u.t. (11.28 s)	63 u.t.	90.63%
309->609 u.t.	666 u.t.	612 u.t. (11.369 s)	54 u.t.	91.89%
310->610 u.t.	670 u.t.	612 u.t. (11.369 s)	58 u.t.	91.34%
311->611 u.t.	669 u.t.	612 u.t. (11.369 s)	57 u.t.	91.48%
312->612 u.t.	665 u.t.	617 u.t. (11.406 s)	48 u.t.	92.78%
313->613 u.t.	668 u.t.	617 u.t. (11.406 s)	51 u.t.	92.37%
314->614 u.t.	669 u.t.	617 u.t. (11.406 s)	52 u.t.	92.23%
315->615 u.t.	669 u.t.	617 u.t. (11.406 s)	52 u.t.	92.23%
316->616 u.t.	669 u.t.	617 u.t. (11.406 s)	52 u.t.	92.23%
317->617 u.t.	664 u.t.	620 u.t. (11.563 s)	44 u.t.	93.37%
318->618 u.t.	667 u.t.	620 u.t. (11.563 s)	47 u.t.	92.95%
319->619 u.t.	668 u.t.	620 u.t. (11.563 s)	48 u.t.	92.81%
320->620 u.t.	662 u.t.	623 u.t. (11.588 s)	39 u.t.	94.11%
321->621 u.t.	667 u.t.	623 u.t. (11.588 s)	44 u.t.	93.40%
322->622 u.t.	665 u.t.	623 u.t. (11.588 s)	42 u.t.	93.68%
323->623 u.t.	661 u.t.	626 u.t. (11.677 s)	35 u.t.	94.70%
324->624 u.t.	666 u.t.	626 u.t. (11.677 s)	40 u.t.	93.99%
325->625 u.t.	665 u.t.	626 u.t. (11.677 s)	39 u.t.	94.14%
326->626 u.t.	660 u.t.	627 u.t. (8.22 s)	33 u.t.	95.00%
327->627 u.t.	658 u.t.	629 u.t. (11.938 s)	29 u.t.	95.59%
328->628 u.t.	663 u.t.	629 u.t. (11.938 s)	34 u.t.	94.87%
329->629 u.t.	658 u.t.	630 u.t. (8.139 s)	28 u.t.	95.74%
330->630 u.t.	656 u.t.	634 u.t. (11.941 s)	22 u.t.	96.65%
331->631 u.t.	660 u.t.	634 u.t. (11.941 s)	26 u.t.	96.06%
332->632 u.t.	659 u.t.	634 u.t. (11.941 s)	25 u.t.	96.21%
333->633 u.t.	659 u.t.	634 u.t. (11.941 s)	25 u.t.	96.21%
334->634 u.t.	656 u.t.	635 u.t. (8.96 s)	21 u.t.	96.80%

Fonte: Elaborado pelo autor (2013).

Os dados foram calculados para uma TR de 8 segundos. A primeira coluna: Janela, está demarcando em u.t. (unidade de tempo) os intervalos separados, como falado anteriormente. A próxima coluna: Previsão, é o calculo do algoritmo em

unidade de tempo para a determinada janela. A coluna Correto seria a próxima unidade tempo que ultrapassaria os 8 segundos de TR a partir daquela janela, contendo o valor parênteses que foi ultrapassado. Dif. acerto é a coluna que mostra o total de unidades de tempo que o algoritmo errou, quanto mais próximo de zero, melhor. Por fim, a coluna Prob. acerto é a probabilidade de acerto em percentual do algoritmo naquela determinada janela.

Nota-se uma incrementação considerável no percentual de acerto, isso deve-se ao fato do início dos dados estarem bastante aleatórios, e conforme vai passando eles vão tomando uma certa forma.

6 CONSIDERAÇÕES FINAIS

A Mineração de Dados vem tornando-se uma ferramenta com papel fundamental na gestão da informação das organizações. A manipulação dos dados e a análise das informações de maneira manual tornou-se inviável devido ao grande volume de dados coletados diariamente e armazenados em bases históricas, e de volume gigantesco muitas vezes.

O monitor desenvolvido utilizando Regressão Linear demonstrou que essa técnica tem potencial para a tarefa sugerida. Podemos notar que quanto mais dados temos para minerar, mais correto é o resultado.

E para trabalhos futuros, ficam como sugestões:

- Desenvolvimento do algoritmo de regressão não-linear, para que possa ser comparado os resultados.
- Implementar o algoritmo desenvolvido para calcular em tempo real.
- Desenvolver a parte de monitoramento completa utilizando o algoritmo sugerido para a previsão dos dados de tempo de resposta. Isso não foi desenvolvido, pois o objetivo era observar os dados obtidos e ver se o algoritmo é viável para esse tipo de uso.

REFERÊNCIAS

ALVES, A. et al. Web Services Business Process Execution Language Version 2.0.

OASIS, 2007. Disponível em: <<http://docs.oasis-open.org/wsbpel/2.0/OS/wsbpel-v2.0-OS.html>>. Acesso em: 2 maio 2012.

BARESI, L.; GUINEA, S. **Towards dynamic monitoring of WS-BPEL processes**. Amsterdam: Springer, 2005.

BARRETO, J. M. **Introdução às Redes Neurais Artificiais**. Florianópolis, 2002.

Disponível em: <<http://www.inf.ufsc.br/~barreto/tutoriais/Survey.pdf>>. Acesso em: 2 maio 2012.

BOOTH, D. et al. Web Services Architecture. **W3C**, 2004. Disponível em:

<<http://www.w3.org/TR/ws-arch>>. Acesso em: 2 maio 2012.

BORTOLI, G.; PIGNAT FILHO, J. C.; MENDES, A. G. **Datamining**. Chapecó, 2005.

Disponível em: <<http://pt.scribd.com/andreitsbr/d/2870027-DataMining>>. Acesso em: 2 maio 2012.

CAMILO, C. O.; DA SILVA, J. C. **Mineração de Dados: Conceitos, Tarefas, Métodos e Ferramentas**. Goiás, 2009. Disponível em:

<http://www.inf.ufg.br/sites/default/files/uploads/relatorios-tecnicos/RT-INF_001-09.pdf>. Acesso em: 20 maio 2013.

CHINNICI, R.; MOREAU, J.; RYMAN, A. Web Services Description Language (WSDL) Version 2.0 Part 1: Core Language. **W3C**, 2007. Disponível em:

<<http://www.w3.org/TR/wsdl20>>. Acesso em: 2 maio 2012.

CIRIACO, D. O que é Inteligência Artificial?. **Tecmundo**, 2008. Disponível em:

<<http://www.tecmundo.com.br/intel/1039-o-que-e-inteligencia-artificial-.htm>>. Acesso em: 2 maio 2012.

DIAS, M. M. **Um modelo de formalização do processo de sistema de descoberta de Conhecimento em banco de dados**. 2001. Tese (Doutorado em Engenharia de Produção). Universidade Federal de Santa Catarina, Florianópolis, 2001.

ERL, T. **Service-Oriented Architecture: Concepts, Technology, and Design**. [S.l.]: Prentice Hall, 2005.

FANTINATO, M. **Uma Abordagem Baseada em Características para o Estabelecimento de Contratos Eletrônicos para Serviços Web**. 2007. 229 f. Tese (Doutorado em Ciência da Computação). Universidade Estadual de Campinas, Campinas, 2008.

FAYYAD, U. M.; PIATESTKY S. G.; SMYTH, P. **From data mining to knowledge discovery: an overview**. Advances knowledge discovery and data mining. Menlo Park: AAAI, 1996a.

FAYYAD, U. M.; PIATETSKY S. G.; SMYTH, P. **The KDD process for extracting useful knowledge from volumes of data**. Communications of the ACM, v. 39, no. 11, 1996b.

FREITAS, C. M. D. S. et al. **Introdução à visualização de informações**. Revista de Informática Teórica e Aplicada, Porto Alegre, 2001.

GARCIA, K. M. **Detecção e Recuperação de Falhas em Web Services**. Florianópolis, 2007. Disponível em: <http://projetos.inf.ufsc.br/arquivos_projetos/projeto_581/tcc_vs_final.pdf>. Acesso em: 2 maio 2012.

GOEBEL, M.; GRUENWALD, L. **A Survey of Data Mining and Knowledge Discovery Software Tools**. ACM SIGKDD Explorations. Nova York, 1999.

GOLDSCHMIDT, R.; PASSOS, E. **Data Mining um guia pratico**. Rio de Janeiro: Campus, 2005.

HAN, J.; KAMBER, M. **Data Mining: Concepts and Techniques**. Elsevier, 2006.

JUNGES, L. C. D. **Introdução a Lógica Fuzzy**. Santa Catarina, 2006. Disponível em: <<http://s2i.das.ufsc.br/tikiwiki/apresentacoes/logica-fuzzy.pdf>>. Acesso em: 2 maio 2012.

KODALI, R. R. What is service-oriented architecture?. **Java World**, 2005. Disponível em: <<http://www.javaworld.com/javaworld/jw-06-2005/jw-0613-soa.html>>. Acesso em: 2 maio 2012.

LUBLINSKY, B. Defining SOA as an architectural style. **IBM**, 2007. Disponível em: <<http://www.ibm.com/developerworks/architecture/library/ar-soastyle/>> Acesso em: 2 maio 2012.

MAAMAR, Z. et al. **From Communities of Web Services to Marts of Composite Web Services**. Dubai: [s.n.], 2010.

MICHLMAYR, A. et al. **Comprehensive QoS monitoring of Web services and event-based SLA violation detection**. Nova York: [s.n.], 2009.

PAPAZOGLU, M. et al. **Service-Oriented Computing: A Research Roadmap**. [S.I.]: World Scientific, 2008.

PICHILIANI, M. Data Mining na Prática: Classificação Bayesiana. **iMasters**, 2006. Disponível em: <<http://imasters.com.br/artigo/4926/sql-server/data-mining-na-pratica-classificacao-bayesiana/>>. Acesso em: 21 maio 2013.

POSTAL, E. C. **Módulo de Monitoramento de Serviços Web em CWSMarts Utilizando Aspectos**. Porto Alegre, 2011. Disponível em: <<http://www.lume.ufrgs.br/handle/10183/31029>>. Acesso em: 23 abr. 2012.

RABELO, E. **Avaliação de técnicas de visualização para mineração de dados**. Maringá, 2007. Disponível em: <<http://www.din.uem.br/~mestrado/diss/2007/rabelo.pdf>>. Acesso em: 25 mar. 2013.

SANTOS L. L. **Monitoramento de Contratos Eletrônicos baseados em Características**. 2011. 113 f. Dissertação (Mestrado em Ciência da Computação). Universidade Estadual de Campinas, Campinas, 2011.

SHIMABUKURU, H. M. **Visualização temporal em uma plataforma software extensível e adaptável**. Tese (Doutorado em Ciência Matemática e de Computação). Universidade de São Paulo, São Carlos, 2004.

SOBRINHO, R. O que é SOA?. **Oficina da Net**, 2011. Disponível em: <http://www.oficinadanet.com.br/artigo/desenvolvimento/o_que_e_soa_arquitetura_orientada_a_servicos>. Acesso em: 2 maio 2012.

WESKE M. **Business Process Management: Concepts, Languages, Architectures**. [S.I.]: Springer, 2007.

APÊNDICE A – ARTIGO CIENTÍFICO

MONITORAMENTO DE SERVIÇOS WEB PARA PREVER POSSÍVEIS FALHAS.

Rafael Frenhe Beraldo¹, Prof. Me. Anderson Francisco Talon², Prof. Dr. Élvio Gilberto da Silva³, Prof. Me. Wiliam Carlos Galvão⁴.

RESUMO

Organizações atualmente tendem a trabalhar cooperativamente para atingir objetivos em comum e focarem nas atividades principais do negócio, um dos métodos para que isso ocorra é em forma de terceirização de serviços. A Computação Orientada a Serviços sugere um modelo para o desenvolvimento de sistemas distribuídos, onde fornecedores desenvolvem seus serviços e os guardam em seus servidores públicos para que consumidores de tais serviços possam utilizá-los. Contratos eletrônicos são negociados e definidos previamente entre as partes para manter a integridade dos sistemas, porém muitos fatores podem impedir que as regras dos contratos sejam seguidas, portanto é importante que os serviços sejam monitorados para que comportamentos indesejáveis sejam detectados. Este trabalho apresenta um método de monitoramento do tempo de resposta das requisições de serviços web para previsão de quebra de contrato com auxílio de inteligência artificial.

Palavras-chave: Monitoramento. Inteligência Artificial. Serviços Web.

1 INTRODUÇÃO

Organizações atualmente tendem a trabalhar cooperativamente para atingir objetivos em comum e focarem nas atividades principais do negócio, um dos métodos para que isso ocorra é em forma de terceirização de serviços. Serviços web são aplicações cujo objetivo é prover uma funcionalidade capaz de ser invocada por aplicações de consumidores de tais serviços, estes são a mais simples utilização de AOS (Arquitetura Orientada a Serviço) aplicando os principais padrões SOAP (*Simple Object Access Protocol*) e WSDL (*Web Services Description Language*) (MICHELMAYR et al., 2009; POSTAL, 2011).

O modelo de COS (Computação Orientada a Serviços) sugere que, fornecedores desenvolvam seus serviços e os publiquem na linguagem padrão WSDL para que consumidores de tais serviços possam utilizá-los (CHINNICI et al.,

¹ Orientando - rafael.beraldo@usc.edu.br

² Orientador - anderson.talon@usc.br

³ Banca examinadora - egsilva@usc.br

⁴ Banca examinadora - wiliam.galvao@yahoo.com.br

2006). É também comum encontrarmos serviços compostos, que são desenvolvidos para cumprir objetivos mais extensos (POSTAL, 2011).

Contratos eletrônicos são negociados e definidos previamente entre as partes para manter a integridade dos sistemas, porém algumas questões como sobrecarga de pedidos ou até mesmo alteração dos serviços pelos fornecedores podem impedir que as regras dos contratos sejam seguidas. Precisam ser criados de modo que possam ser executados e monitorados (SANTOS, 2011).

Segundo Baresi e Guinea (2005), o monitoramento contínuo dos contratos e serviços é uma das soluções para estas objeções. Com os monitores operando em tempo de execução com auxílio de técnicas de programação defensiva é possível que comportamentos indesejáveis sejam detectados e tratados.

O foco do trabalho foi desenvolver um monitoramento do tempo de resposta dos serviços através da análise de dados de execuções anteriores, de modo que o contrato possa ser revisado e renegociado antes da quebra do mesmo.

IA (Inteligência Artificial) estuda a forma de pensar do ser humano e busca implementar isso em linguagem de máquina, é exatamente o que buscamos quando se trava de previsão de informação. O monitoramento do tempo de resposta das requisições utilizando IA visa prever tais irregularidades, como a quebra do contrato, para que providências sejam tomadas.

2 FUNDAMENTAÇÃO TEÓRICA

2.1 MINERAÇÃO DE DADOS

Conforme Bortoli et. al. (2005, p. 2) Mineração de Dados (Datamining) é

[...] o processo de extrair informação válida, previamente desconhecida e de máxima abrangência a partir de grandes bases de dados, usando-as para efetuar decisões cruciais. O Datamining vai muito além da simples consulta a um banco de dados, no sentido de que permite aos usuários explorar e inferir informação útil a partir dos dados, descobrindo relacionamentos escondidos no banco de dados.

Nas próximas seções são descritas resumidamente as principais tarefas e técnicas de MD.

2.2 TAREFAS DA MINERAÇÃO DE DADOS

As tarefas correspondem aos problemas que podem ser tratados pela mineração de dados. As tarefas mais comuns são:

Descrição (*Description*): Segundo Camilo e Silva (2009), é a tarefa utilizada para descrever os padrões e tendências revelados pelos dados. A descrição geralmente oferece uma possível interpretação para os resultados obtidos. A tarefa de descrição é muito utilizada em conjunto com as técnicas de análise exploratória de dados, para comprovar a influência de certas variáveis no resultado obtido.

Classificação (*Classification*): É uma das tarefas mais importantes e populares conhecidas. Tarefa de classificação consiste em construir um modelo de algum tipo que possa ser aplicado a dados não classificados visando categorizá-los em classes. Exemplo: num levantamento de regiões com probabilidade de existência de mosquito da dengue. Sendo possível criar classes de baixa, médio e alto risco de contaminação.

Associação (*Association*): Procuram encontrar associações entre conjunto de valores. Um exemplo clássico é determinar quais produtos costumam serem colocados juntos em um carrinho de supermercado. Outra definição seria: "a tarefa de associação pode ser considerada uma tarefa bem definida, determinística e relativamente simples, que não envolve predição da mesma forma que a tarefa de classificação" (FREITAS, 2000 apud DIAS, 2000, p. 10). Exemplo: determinar quais produtos geralmente são colocados juntos em um carrinho de supermercado.

Agrupamento (*Clustering*): Usado para particionar os registros de uma base de dados em subconjuntos ou *clusters*. Nesta tarefa, não há classes predefinidas, os registros são agrupados segundo algum critério de semelhança. Exemplos (DIAS, 2001):

- Agrupar clientes por região do país;
- Agrupar clientes com comportamento de compra similar
- Agrupar seções de usuários Web para prever comportamento futuro de usuário.

Regressão (*Regression*) ou Estimação (*Estimation*): Esta tarefa é similar à tarefa de classificação, porém é usada quando o registro é identificado por um valor numérico e não categórico. Ela busca por funções que mapeiem os registros de um banco de dados. Exemplos (DIAS, 2001):

- Estimativa da probabilidade de um paciente sobreviver, dado o resultado de um conjunto de diagnóstico de exames;
- Definição do limite do cartão de crédito para cada cliente em um banco;
- Estimativa do número de filhos ou a renda total de uma família;
- Previsão da demanda de um consumidor para um novo produto.

Predição (*Prediction*): É similar às tarefas de classificação e estimação, porém ela visa descobrir o valor futuro de um determinado atributo. Exemplos (CAMILO e SILVA, 2009):

- Predizer o valor de uma ação três meses adiante;
- Predizer o percentual que será aumentado de tráfego na rede se a velocidade aumentar;
- Predizer o vencedor do campeonato baseando-se na comparação das estatísticas dos times.

Alguns métodos de classificação e regressão podem ser usados para predição, com as devidas considerações.

Sumarização (*Summarization*): Consiste em identificar e apresentar, de forma concisa e compreensível, as principais características dos dados em um conjunto de dados (DIAS, 2001).

Exemplo: identificar as características dos candidatos de um concurso público: São pessoas com faixa etária entre X e Y anos, possuem casa própria e nível superior completo (RABELO, 2007).

Exemplos:

- Tabular o significado e desvios padrão para todos os itens de dados;
- Derivar regras de síntese.

Segundo Rabelo (2007), após a seleção de qual tarefa utilizar, precisa-se também escolher o algoritmo, já que para cada tarefa existem diferentes algoritmos, alguns simples e outros mais complexos, como os algoritmos que utilizam redes neurais.

2.3 MÉTODOS E TÉCNICAS DA MINERAÇÃO DE DADOS

As tarefas de mineração de dados são desempenhadas por técnicas de mineração de dados e diferentes técnicas servem para diferentes propósitos (RABELO 2007 apud HARRISON, 1998).

Será mostrada somente as técnicas de regressão, foco deste trabalho.

Regressão Linear (*Linear Regression*): As regressões "lineares" quando a relação entre as variáveis de previsão e a resposta seguem um comportamento contínuo (linear). Quando isso ocorre, é possível criar um modelo no qual o valor de y é uma função linear de x . Na Figura 1 pode-se ver um exemplo de uma regressão linear (CAMILO e SILVA, 2009).

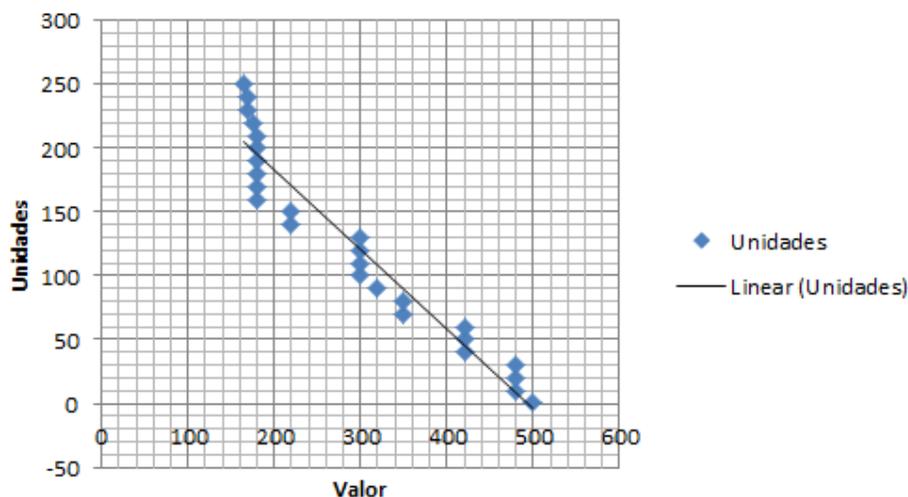


Figura 1 - Regressão Linear.
Fonte: Elaborado pelo autor (2013).

Regressão Não-linear (*Nonlinear Regression*): "Nos modelos de regressão não-linear, a relação entre as variáveis de previsão e a resposta não segue um comportamento linear. Por exemplo, a relação entre as variáveis pode ser modelada como uma função polinomial. [...]" (CAMILO e SILVA, 2009, p. 17).

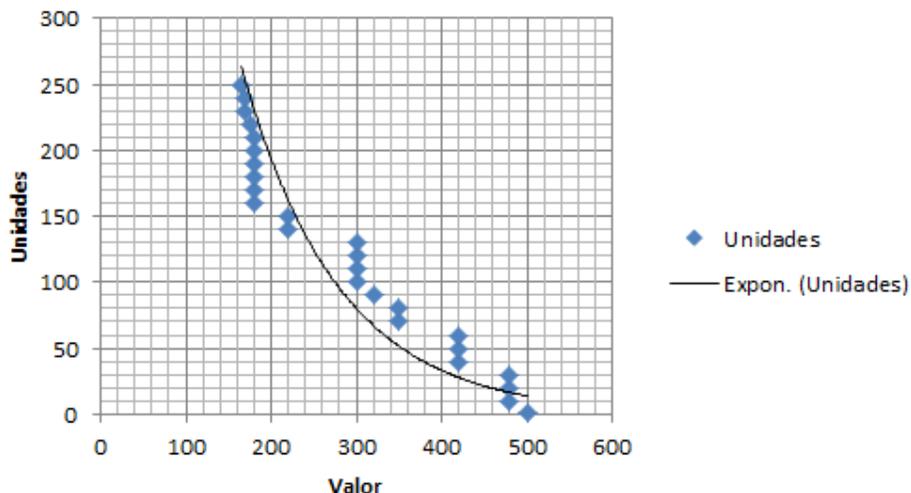


Figura 2 - Regressão Não-linear.
Fonte: Elaborado pelo autor (2013).

3 PROTÓTIPO

O propósito do trabalho foi examinar se a técnica de Regressão Linear é adequada e traz os resultados esperados para a aplicação. A monitoração faz a leitura de execuções anteriores de um arquivo de log, utilizando a técnica de Inteligência Artificial citada acima, e é esperado que se obtenha uma previsão correta ou parcialmente correta das próximas execuções. Como por exemplo: foi decidido entre as entidades que o tempo de resposta do serviço contratado deve ser inferior a 6 segundos, porém o monitor prevê que o contrato será quebrado nas próximas 20 execuções, então é feita a comunicação com o fornecedor para que seja feita uma recontractação, ou para que seja tomada alguma providência evitando que isso ocorra (trabalho futuro).

O arquivo de log utilizado possui as seguintes informações: número (contador) da requisição, tempo total da resposta, agente consumidor e agente fornecedor (podendo haver variações e modificações para melhor implementação). De forma simples para facilitar o desenvolvimento do propósito.

4 RESULTADOS

Utilizando o ambiente de programação Delphi, foi criada uma pequena aplicação que faria uma chamada do serviço mais simples do Google: a página de pesquisa. Essa aplicação fez a chamada do serviço de um em um segundo durante uma hora e foram obtidos 870 valores, depois todos estes dados foram copiados

para o Microsoft Excel para gerar o gráfico. Os dados eram reais e perfeitos para uso, como mostra a Figura 3.

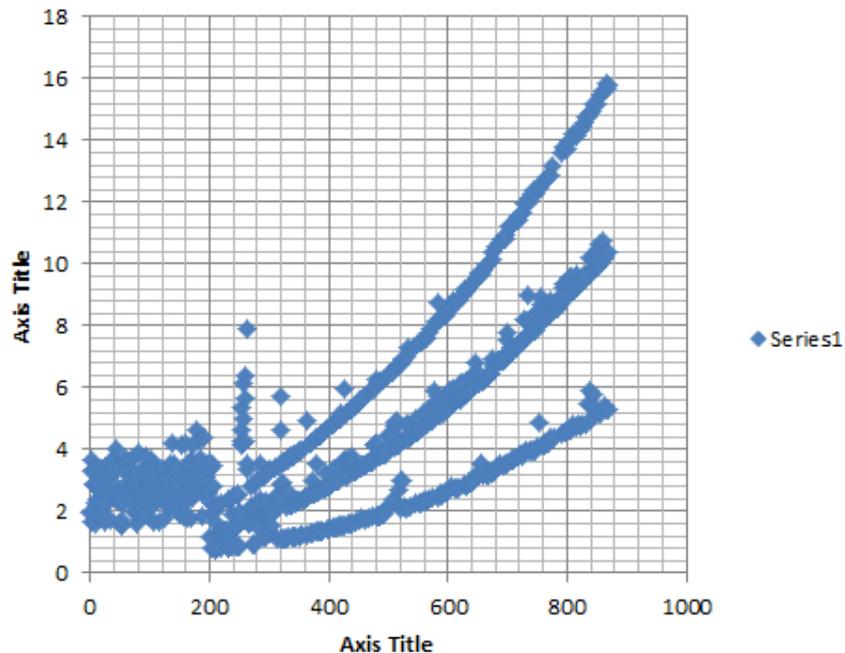


Figura 11 - Gráfico dos dados reais.
Fonte: Elaborado pelo autor (2013).

O próximo passo foi dividir os dados em janelas de 100 (divisões), de modo que tivesse a janela de 0 a 100, 1 a 101, 2 a 102, 3 a 103 e etc. O objetivo era usar as janelas como se fossem os dados de execuções passadas, e as unidades seguintes como execuções futuras (por exemplo: os dados seguintes da janela de 2 a 102 seriam do 103 em diante), que seriam nossa previsão. Feito isso agora era necessário aplicar o algoritmo de Regressão Linear, que é possível ser feito no Excel.

A formula para Regressão Linear:

$$y = ax + b$$

Onde:

- **y**: é a variável de previsão, a linha vertical no gráfico.
- **a**: é o resultado da formula de inclinação, que pode ser obtida no Excel utilizando a função INCLINAÇÃO (SLOPE).
- **x**: é a unidade de tempo, a linha horizontal no gráfico.

- **b**: é o resultado da fórmula de intercepção, que pode ser obtida no Excel utilizando a função INTERCEPÇÃO (INTERCEPT).

Mas o valor de y já era conhecido, portanto era necessário encontrar o valor de x , invertendo a equação ficará:

$$x = (-b + y) / a$$

A fórmula de inclinação é:

$$\frac{n \sum(xy) - \sum x \sum y}{n \sum x^2 - (\sum x)^2}$$

Onde:

- **x**: é a unidade de tempo, a linha horizontal no gráfico.
- **y**: os valores de fato (dados obtidos), a linha vertical no gráfico.

A fórmula de intercepção é:

$$\frac{\sum x^2 \sum y - \sum(xy) \sum x}{n \sum x^2 - (\sum x)^2}$$

Onde:

- **x**: é a unidade de tempo, a linha horizontal no gráfico.
- **y**: os valores de fato (dados obtidos), a linha vertical no gráfico.

Conforme o andamento, as janelas foram aumentadas para 300 (1 a 300, 2 a 302, 3 a 303, etc.), pois as previsões não estavam muito bem em virtude da pouca quantidade de dados anteriores, e os valores totais foram diminuídos para 700.

Até aqui tudo havia sido feito no Excel, porém foi necessário migrar, pois seria necessário fazer várias verificações para saber qual a próxima unidade de tempo que "estouraria" o tempo limite a partir da atual janela. Seria necessário criar vários itens de "primeira ocorrência", um para cada janela praticamente. Portanto, foi tudo refeito numa aplicação PHP, onde poderia ser feito tudo de maneira automática.

Os dados foram calculados com uma TR (tempo de resposta - máximo) de 8 segundos, e a probabilidade de acerto das previsões foram subindo conforme mais dados eram analisados. De zero à 96,8% e com a média de 56,5% de chance de acerto.

5 CONSIDERAÇÕES FINAIS

A Mineração de Dados vem tornando-se uma ferramenta com papel fundamental na gestão da informação das organizações. A manipulação dos dados e a análise das informações de maneira manual tornou-se inviável devido ao grande volume de dados coletados diariamente e armazenados em bases históricas, e de volume gigantesco muitas vezes.

O monitor desenvolvido utilizando Regressão Linear demonstrou que essa técnica tem potencial para a tarefa sugerida. Podemos notar que quanto mais dados temos para minerar, mais correto é o resultado.

E para trabalhos futuros, ficam como sugestões:

- Desenvolvimento do algoritmo de regressão não-linear, para que possa ser comparado os resultados.
- Implementar o algoritmo desenvolvido para calcular em tempo real.
- Desenvolver a parte de monitoramento completa utilizando o algoritmo sugerido para a previsão dos dados de tempo de resposta. Isso não foi desenvolvido, pois o objetivo era observar os dados obtidos e ver se o algoritmo é viável para esse tipo de uso.

WEB SERVICES MONITORING TO PREDICT POTENTIAL FAILURES. Rafael Frenhe Beraldo.

ABSTRACT

Organizations today tend to work cooperatively to achieve common goals and focus on core business activities, one of the methods for this is outsourcing services. The Service-Oriented Computing suggests a model for developing distributed systems, where suppliers develop their services and keep them in their public servants so that consumers of such services can use them. Electronic contracts are negotiated and defined previously between the parties to maintain the integrity of systems, but many factors can prevent the contract rules are followed, so it is important that services are monitored so that undesirable behaviors are detected. This paper presents a method for monitoring the response time of web service requests for predicting breach of contract with the aid of artificial intelligence.

Keywords: Monitoring. Artificial Intelligence. Web Services.

REFERÊNCIAS

BARESI, L.; GUINEA, S. **Towards dynamic monitoring of WS-BPEL processes.**

Amsterdam: Springer, 2005.

BORTOLI, G.; PIGNAT FILHO, J. C.; MENDES, A. G. **Datamining.** Chapecó, 2005.

Disponível em: <<http://pt.scribd.com/andreitsbr/d/2870027-DataMining>>. Acesso em: 2 maio 2012.

CAMILO, C. O.; DA SILVA, J. C. **Mineração de Dados: Conceitos, Tarefas, Métodos e Ferramentas.** Goiás, 2009. Disponível em:

<http://www.inf.ufg.br/sites/default/files/uploads/relatorios-tecnicos/RT-INF_001-09.pdf>. Acesso em: 20 maio 2013.

CHINNICI, R.; MOREAU, J.; RYMAN, A. Web Services Description Language (WSDL) Version 2.0 Part 1: Core Language. **W3C**, 2007. Disponível em:

<<http://www.w3.org/TR/wsdl20>>. Acesso em: 2 maio 2012.

DIAS, M. M. **Um modelo de formalização do processo de sistema de descoberta de Conhecimento em banco de dados.** 2001. Tese (Doutorado em Engenharia de Produção). Universidade Federal de Santa Catarina, Florianópolis, 2001.

FREITAS, C. M. D. S. et al. **Introdução à visualização de informações.** Revista de Informática Teórica e Aplicada, Porto Alegre, 2001.

MICHLMAYR, A. et al. **Comprehensive QoS monitoring of Web services and event-based SLA violation detection**. Nova York: [s.n.], 2009.

POSTAL, E. C. **Módulo de Monitoramento de Serviços Web em CWSMarts Utilizando Aspectos**. Porto Alegre, 2011. Disponível em:
<<http://www.lume.ufrgs.br/handle/10183/31029>>. Acesso em: 23 abr. 2012.

RABELO, E. **Avaliação de técnicas de visualização para mineração de dados**. Maringá, 2007. Disponível em:
<<http://www.din.uem.br/~mestrado/diss/2007/rabelo.pdf>>. Acesso em: 25 mar. 2013.

SANTOS L. L. **Monitoramento de Contratos Eletrônicos baseados em Características**. 2011. 113 f. Dissertação (Mestrado em Ciência da Computação). Universidade Estadual de Campinas, Campinas, 2011.