

DELFO: A Model for Multitemporal Analysis Based on Context Histories

M. G. Martins, L. C. Nesi, P. R. S. Pereira, and J. L. V. Barbosa

Abstract—This paper presents Delfos, a model for multitemporal analysis based on context histories. The article describes the model architecture, implementation, and tests with two real datasets to evaluate the functionality and its potential to real applications. The first scenario used historical data from an electric power transmission substation, and the second with data from the performance analysis of futsal athletes. The results obtained through inference rules perform with 100% accuracy of the profiles creation and that profiles and current context data are a better representation of the present, than only the current context data of the application. The results on the prediction of contexts were relevant in the case of the existence of behavior patterns in the contexts of the analyzed entities. For the application related to the electric power transmission substation, the assertiveness was between 86% and 92% in a 12-hour interval. In the application of performance analysis of futsal athletes, we made predictions about the athletes' movement, with results varying between 72% and 92% for the time of up to 20 seconds. The results were encouraging and show potential for implementing Delfos in real-life situations.

Index Terms—Ubiquitous Computing, Context-aware Computing, Contexts Histories and Contexts Prediction, Similarity Analysis, Profile Management

I. INTRODUÇÃO

A crescente expansão no uso de recursos de tecnologia da informação e comunicação vem estimulando a adoção da computação ubíqua e suas tecnologias relacionadas, tais como sistemas com sensibilidade ao contexto, e sistemas onde podem ser aplicados os conceitos de computação baseada em contexto, como Internet das Coisas e Sistemas Ciber-físicos, para aumento da proatividade. Nos últimos anos houve uma significativa evolução tecnológica dos dispositivos móveis e das tecnologias de acesso à Internet, possibilitando assim, um avanço nas pesquisas relacionadas com a computação ubíqua, permitindo o surgimento de oportunidades em diversas áreas como saúde e bem estar, educação, jogos, comércio, acessibilidade, transportes, agricultura, entre outros. Essa realidade vem oportunizando o desenvolvimento de soluções tecnológicas cada vez mais integradas com o cotidiano das pessoas.

Nesse cenário tecnológico, visualiza-se a possibilidade de integrar os conceitos apresentados pela computação ubíqua, relacionados a contextos, com as tecnologias e metodologias, como Internet das Coisas e Sistemas Ciber-físicos. Essa integração pode se dar em um cenário multitemporal [1] [2]

pois, a computação sensível a contextos, possibilita trabalhar com o passado através dos históricos de contextos [1] [3], com o presente visualizado pelo contexto atual, pelo perfil [4], ou por ambos e pelo futuro que pode ser trabalhado por meio da predição de contextos [5] tendo, como base, os dados atuais e do passado de uma entidade.

Diante deste panorama, esse trabalho propõe o Delfos, um modelo para análise multitemporal baseado em históricos de contextos. O modelo faz uso do contexto do passado que é representado por meio dos históricos de contextos. Já o contexto presente é representado tanto através dos contextos atuais de entidades, como também pelo Perfil da entidade, que guarda um resumo dos dados relevantes do histórico de contextos baseado em regras específicas. Por fim, o contexto futuro, é contemplado pela predição de contextos.

O objetivo principal do Delfos é aumentar a inteligência das aplicações possibilitando que um sistema possa, através da análise multitemporal retornar para uma configuração de bom desempenho do passado, ou prever problemas futuros e adaptar o sistema em decorrência dessa predição. No estudo realizado através de mapeamento sistemático, cabe notar que não foram encontrados trabalhos que contemplem a análise multitemporal baseada em contextos com as três dimensões, conforme proposto pelo Delfos.

O Delfos foi avaliado em dois estudos de casos, o primeiro sobre dados históricos de uma subestação de transmissão de energia elétrica de uma distribuidora, e o segundo com dados de análise de desempenho de atletas de futsal. Os resultados mostraram que o Delfos, através de regras de inferência definidas pela aplicação, realiza com precisão de 100% a criação de perfis e que estes são uma representação melhor do presente, que apenas os dados de contexto atuais da aplicação. Os resultados, em relação à predição de contextos, foram relevantes no caso da existência de padrão do comportamento dos contextos das entidades analisadas. Para a aplicação relacionada à distribuidora de energia elétrica, os acertos estiveram entre 86% e 92% para tempos de 12 horas. Na aplicação de análise de desempenho de atletas de futsal, foram realizadas predições em relação à movimentação dos atletas, com resultados variando entre 72% e 92% para o tempo de até 20 segundos.

O restante do artigo está organizado da seguinte forma. A seção II apresenta estudos relacionados. A seção III apresenta a arquitetura do modelo proposto, que incorpora quatro módulos e cinco bases de dados. A metodologia de avaliação e as características dos testes estão incluídas na seção IV, seguido da discussão e a análise dos resultados experimentais. A seção V conclui este artigo e orienta trabalhos futuros.

M. G. Martins, Universidade do Vale do Rio dos Sinos (UNISINOS), São Leopoldo, Rio Grande do Sul, Brasil, marciog@unisinis.br.

L. C. Nesi, Universidade do Vale do Rio dos Sinos (UNISINOS), São Leopoldo, Rio Grande do Sul, Brasil, lcnesi@unisinis.br.

P. R. S. Pereira, Universidade do Vale do Rio dos Sinos (UNISINOS), São Leopoldo, Rio Grande do Sul, Brasil, prpereira@unisinis.br.

J. L. V. Barbosa, Universidade do Vale do Rio dos Sinos (UNISINOS), São Leopoldo, Rio Grande do Sul, Brasil, jbarbosa@unisinis.br.

II. TRABALHOS RELACIONADOS

Nesta seção são listadas contribuições para históricos de contextos (passado), contexto atual, perfil ou ambos (presente) e predição de contextos (futuro) relacionadas a esta pesquisa. Referente ao passado, foi verificado se o trabalho faz uso de históricos de contextos, em relação ao presente, foi analisado se o trabalho faz referência à utilização de perfil, contexto atual ou ambos. Já em relação ao aspecto temporal do futuro, foram investigados quais algoritmos de predição foram empregados.

Rosa *et al.* [1] propuseram um sistema multitemporal baseado em contextos para o gerenciamento de competências. O modelo proposto aplica variados níveis de proficiência e aproveita os contextos atuais e passados dos trabalhadores, para ajudá-los a desenvolver suas competências. Voigtmann, Lau e David [6] propuseram a predição de contextos colaborativos (*Collaborative Context Prediction – CCP*) para suprir a lacuna de informações, de contextos ausentes, no histórico de contextos do usuário.

Pejovic e Musolesi [7] apresentaram o estado da arte em sensoriamento móvel e predição de contexto, e como isso pode ser aplicado para uma computação móvel antecipada (*anticipatory mobile computing*). O artigo apresenta um levantamento das possibilidades de utilização dos telefones celulares, para inferir contextos, através dos sensores presentes nos mesmos, e realizar predições para tornar os sistemas computacionais proativos. Os autores oferecem também uma descrição das técnicas de aprendizado de máquina mais usadas para realizar predições. Ballings *et al.* [8] compararam diversos algoritmos de predição para avaliar a direção dos preços de ações.

Xu *et al.* [9] desenvolveram uma estrutura *on-line* que pode aprender a situação atual do trânsito, através de dados de sensores de tráfego capturados em tempo real, e realizar previsão do congestionamento futuro. Shaptala e Kyselova [10] apresentaram uma solução para predição de localização em ambientes internos, baseado em aprender hábitos e padrões de comportamento humano. A solução foi construída para um sistema de gerenciamento de energia sensível ao contexto (*Context-Aware Energy Management System - CAEMS*), cujo objetivo é maximizar através da predição o conforto e minimizar o consumo de energia.

Maalej, Ellmann e Robbes [11] propuseram um modelo cujo objetivo é verificar se relações entre tarefas podem ser previstas com base na similaridade dos contextos correspondentes. Hui e Sherratt [12] criaram uma taxonomia para o *Disappearing user interfaces* (DUIs), que é uma interação humano-computador (IHC) que se concentra na interação com o conteúdo e não com a interface, com o intuito de estimular os sentidos humanos e captar respostas automaticamente. Dupont, Barbosa e Alves [13] propuseram um modelo chamado CHSPAM, que permite a descoberta de padrões sequenciais, em bancos de dados de históricos de contextos.

A Tabela I mostra um comparativo entre os trabalhos relacionados e o Delfos. A primeira coluna é referente aos trabalhos analisados, enquanto as demais colunas detalham tecnologias, metodologias ou técnicas de representação de contextos utilizados nestes trabalhos.

Nos trabalhos analisados, pode-se constatar que: (i) todos os trabalhos utilizaram dados referentes ao passado, para permitir

as técnicas de predição; (ii) apenas os trabalhos [1], [6], [9] e [13], usaram o conceito de histórico de contextos; (iii) o conceito de Perfil, para representar os dados da dimensão do presente, em um cenário multitemporal, não foi abordado por nenhum dos trabalhos analisados. Salienta-se que o estudo realizado não encontrou nenhum trabalho que apresente o conceito de análise multitemporal como o proposto pelo Delfos.

III. MODELO DELFOS

O Delfos é um modelo computacional para análise multitemporal baseado em históricos de contextos. Na Figura 1 observa-se a arquitetura do modelo composto por quatro módulos, que são responsáveis por gerenciar o comportamento do modelo, armazenar e trabalhar com dados contidos em suas cinco bases de dados, trazendo as funcionalidades de geração de perfil e predições de contextos, a partir de históricos de contextos e contexto atual. A arquitetura também conta com *Web Services* para prover a entrada de dados e configuração, onde é possível gerenciar a configuração dos parâmetros operacionais.

A. Módulo de Gerenciamento e Configuração

O módulo de gerenciamento e configuração é o responsável por realizar a comunicação, inicialização e configuração dos demais módulos do Delfos, bem como tratar e responder a todas as solicitações de aplicações. A entrada e a saída de dados no Delfos ocorrem através de *Web services REST-Ful*. Todas as mensagens recebidas pelo Delfos são tratadas seguindo o conceito do método GET do protocolo HTTP e necessariamente enviam uma mensagem de resposta.

B. Módulo de Similaridade de Contextos

O módulo de similaridade de contextos é o responsável por criar a estrutura base para realizar predições, realizando duas atividades: (i) criar a partir de históricos de contextos, quando o modelo é inicializado, uma Base de Contextos por Similaridade e (ii) atualizar a Base de Contextos por Similaridade, toda vez que chegar ao modelo um contexto atual de entidades da aplicação.

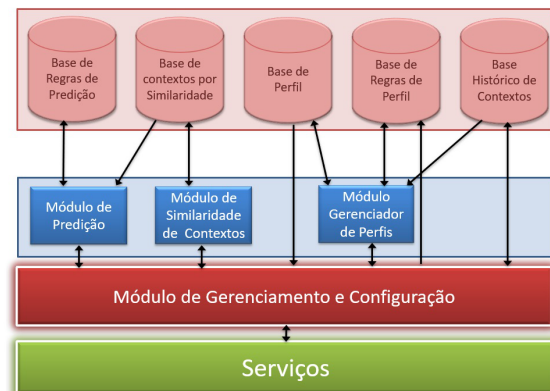


Fig. 1. Arquitetura do modelo Delfos.

TABELA I
COMPARAÇÃO ENTRE OS TRABALHOS RELACIONADOS

Trabalho	Passado	Presente	Futuro
[1]	Histórico de Contextos	Contexto Atual	Não
[6]	Histórico de Contextos	Não	Predição colaborativa de contexto
[7]	Dados Passados	Não	Diversos
[8]	Dados Passados	Contexto Atual	Diversos
[9]	Histórico de Contextos	Contexto Atual	Naive Bayes e Máquina de Vetores de Suporte
[10]	Dados Passados	Não	Random Forest, Máquina de Vetores de Suporte
[11]	Dados Passados	Não	Similaridade Jaccard e FDA
[12]	Dados Passados	Contexto Atual	Modelo oculto de Markov, Redes Bayesianas e Redes Neurais
[13]	Histórico de Contextos	Contexto Atual	Análise de Padrões Sequencias
Delfos	Histórico de Contextos	Contexto Atual e Perfil	Similaridade




Fig. 2. Ontologia do Modelo de contextos do Delfos.

O módulo foi projetado para analisar a similaridade entre contextos armazenados, cujo valor de similaridade é configurado pela aplicação e fica no intervalo de $[0, 1]$, sendo 0 para valores completamente diferentes e 1 para valores iguais. Se o valor especificado, por exemplo, for 0.8, o módulo considera similar todos os contextos em que os valores de similaridade calculada forem maiores ou iguais a 0.8.

Os dados de definição da composição de contextos definem os contextos presentes nas três dimensões temporais. Para o modelo de contextos considera-se a definição apresentada por Dey, Abowd e Salber [14], sendo que os contextos precisam conter informações de: (i) Identidade da entidade, (ii) Tempo, ou seja, a entidade deve considerar uma informação temporal para cada situação, (iii) Localização e (iv) Situação que, no Delfos, são as informações de valores de interesse relacionados à entidade. Delfos usou uma ontologia como método para representação do modelo de contextos, conforme é apresentado na Figura 2, onde cada classe representa os contextos, da maneira definida pelo modelo, e os atributos são exemplos de como podem ser definidos os dados da aplicação.

1) *Medida de Similaridade*: A similaridade é calculada através do uso de funções de similaridade, que servem para definir o grau de semelhança entre dois objetos, que é medido e representado através de um escore [15]. De uma forma simplificada pode ser considerado que, dados dois objetos A e B , a função de similaridade, $sim(A, B) \rightarrow [0, 1]$, indica que o objeto A tem um grau de semelhança com B dentro de um intervalo $[0, 1]$. O valor pode estar em qualquer intervalo, mas como forma de simplificação, normalmente

considera-se um valor normalizado. O grau de semelhança é chamado de escore de similaridade, se um escore for igual a 0 significa que os objetos são completamente diferentes, e se for igual a 1, que eles são completamente iguais. Usualmente, as medidas de distância são os métodos mais naturais, para definir similaridade entre dados numéricos, a exemplo, pode-se citar as distâncias Euclidiana e Manhattan [16].

2) *Funcionamento do Módulo de Similaridade de Contextos*: Esse módulo é inicializado e configurado pelo módulo de gerenciamento e configuração, para tanto é passado o modelo de contextos definido pela aplicação e o valor de similaridade que o módulo deve adotar. Esse valor será entre $[0, 1]$, sendo 0 o valor que representa objetos completamente diferentes e 1 valores iguais. Ou seja, quando o valor do grau de similaridade calculado for maior ou igual que a definição realizada pela aplicação cliente, o módulo considera os contextos avaliados como similares.

A lista de contextos similares é construída com base no histórico de contextos enviado ao Delfos pela aplicação. O histórico de contextos original consiste em uma lista de contextos ordenados pelo valor de contexto "tempo" definido pela aplicação. O módulo de similaridade de contextos começa a realizar uma análise dos contextos a partir dos primeiros dados de contextos da base, ou seja, os mais antigos, sendo esses colocados como os primeiros na lista de contextos similares. Para cada dado adicionado na lista, é gerado um identificador único de similaridade que é adicionado aos dados de contexto. Os próximos dados de contexto do histórico, ou seja, os dados mais antigos após o primeiro na base de histórico de contexto, são comparados com os que já estão na lista de contextos similares. Essa comparação é realizada por meio da análise de similaridade de valores numéricos utilizando a função de distância Euclidiana. Se os dados dos contextos são considerados similares, não é preciso atualizar a lista de contextos similares. No caso de o módulo não considerar similares os dados de contexto, esse novo contexto tem o identificador único de similaridade adicionado aos seus dados de contexto e é inserido na lista. Esse processo é repetido por todo o histórico de contextos e posteriormente com todos os contextos atuais que forem enviados ao Delfos.

No histórico de contextos por similaridade é realizada a

inserção de três informações para representar um contexto: (i) o identificador único de similaridade, (ii) o valor da quantidade de tempo em que ele permaneceu ou permanece como o contexto atual do histórico e (iii) a quantidade de vezes que dados de contextos similares a ele chegaram em sequência.

C. Módulo Gerenciador de Perfis

O módulo gerenciador de Perfis é responsável por realizar a análise do histórico de contextos e gerar um perfil para a entidade a partir de regras definidas pela aplicação. O módulo é inicializado, pelo módulo de Gerenciamento e Configuração, toda vez que chega uma nova regra de perfil ou uma solicitação de Perfil vindo de uma aplicação externa ao Delfos. O módulo então baseado na regra que ele busca na Base de Regras para Perfil, pelo código informado pelo módulo de Gerenciamento e Configuração, realiza a criação do Perfil ou atualização dele na Base de Perfil.

Este módulo é responsável por construir os Perfis, conforme as regras de Perfil recebidas pelo Delfos, vindas de uma aplicação. Ele pode gerar Perfis diferentes para a mesma aplicação, sendo cada Perfil diferenciado por um identificador que é gerado sempre que novas regras de Perfil são solicitadas. Esse identificador é entregue ao módulo de gerenciamento e configuração para que esse repasse a aplicação. Quando a aplicação solicitar o Perfil, ela precisa informar o identificador de Perfil. Quando as regras são informadas, o módulo analisa o histórico de contextos da aplicação, constrói um perfil baseado nas regras e guarda o mesmo na base de Perfis. Quando um Perfil é solicitado, é verificado se ele está atualizado, sendo que todo Perfil possui informações de data e horário da última atualização. Para ser considerado atualizado é realizado um cálculo baseado nas regras de Perfil de tempo informadas, por exemplo, se o Perfil buscado é referente a algo que acontece no primeiro tempo de uma partida de futsal, e a última atualização foi feita em no contexto de tempo do segundo tempo da partida o Perfil é considerado atualizado. Se este estiver atualizado, é informado ao módulo de gerenciamento e configuração, para que esse envie o Perfil para a aplicação; se não estiver, ele é atualizado pelo módulo gerenciador de perfis e o processo de envio para aplicação é realizado.

D. Módulo de Predição

O módulo de predição é responsável por prover o terceiro aspecto da análise multitemporal (futuro) proposto pelo Delfos, realizando a predição de contextos. Este módulo é responsável por analisar, por similaridade de dados, o histórico de contexto e o contexto atual, buscando como será o contexto de uma entidade, em um tempo específico, ou gerar alertas, se a predição verificar que um valor monitorado de um dado de contexto está presente em uma predição para a sequência de contexto. Em ambos os casos, a configuração do módulo com regras de predição é realizada pela aplicação. Essa informação é definida na solicitação enviada pela aplicação externa, ou seja, mensagem de solicitação de predição de contextos. Esse tipo de mensagem é subdividido em quatro e permite que, a aplicação, receba informações de predição de cada um dos quatro tipos de contextos definidos para o modelo de

contexto do Delfos, ou seja: Localização, Tempo, Situação e Identificação.

Na sequência, ele busca o histórico de contextos por similaridade na base de contextos por similaridade e monta uma estrutura de árvore. Esta estrutura é montada como uma Árvore *Trie* [17], onde cada nó contém o identificador único de similaridade gerado pelo módulo de similaridade, que é a chave para pesquisa na árvore e uma lista de objetos contendo informações referentes ao nó filho. Esse objeto contém as seguintes informações: (i) um ponteiro para nó filho na árvore; (ii) o número de vezes que, no histórico de contextos por similaridade, o nó filho vinha em transição direta do nó atual e (iii) a média de tempo que os dados de contextos similares ao do nó atual ficaram antes da transição para o nó filho.

A Figura 3 apresenta como um nó é construído e como funciona a inserção na árvore criada para realizar a predição. O primeiro nó da árvore é construído com a chave sendo o identificador único dos primeiros dados de contextos presentes no histórico de contextos por similaridade, representado na figura pela letra A. Um objeto contendo um ponteiro para um filho desse nó é criado, contendo um ponteiro para o nó que tem como chave o elemento B apresentado na figura. O valor de tempo como contexto atual é adicionado como valor de média de tempo, ficando este como o atual. Na figura o tempo como contexto atual de A é 8:02:30, e 3 é o número de vezes em que existe uma transição de A para B no histórico. Como é a primeira vez que isso acontece o valor adicionado é 1. Esse objeto é adicionado como informação do nó. A inserção da árvore segue o mesmo padrão sendo B a chave do próximo nó e realizando o mesmo processo sucessivamente até encontrar, no histórico de contextos, dados de contextos similares à raiz da árvore no exemplo A.

Quando isso acontece, a inserção volta para a raiz e verifica se a árvore ganha uma nova subárvore ou repete uma transição já realizada. Neste exemplo, acontece novamente uma transição para B, sendo necessário atualizar a média de tempo e aumentar o número de vezes que a transição acontece. Quando é finalizado, a leitura do histórico de contextos apresentado na figura possui dois filhos, os contextos representados por B e C, sendo que a transição para B acontece 3 vezes e tem uma média de tempo de 7:55:25 para acontecer, para os contextos representados por C, acontece apenas uma transição e o tempo é de 6:17:27 para ela ocorrer.

E. Bases de Dados

A arquitetura do Delfos, em conjunto com os demais módulos, faz uso de cinco bases de dados:

- Base de históricos de contextos: armazena os históricos de contextos da aplicação;
- Base de regras de Perfil: armazena as regras de inferência para criação de Perfis;
- Base de Perfil: armazena todos os Perfis já criados, atualizados até a data e hora da última solicitação realizada pela aplicação;
- Base de contextos por similaridade: armazena dois tipos de informação: (i) uma lista de contextos repetidos criada a partir do histórico de contextos, para garantir que todos

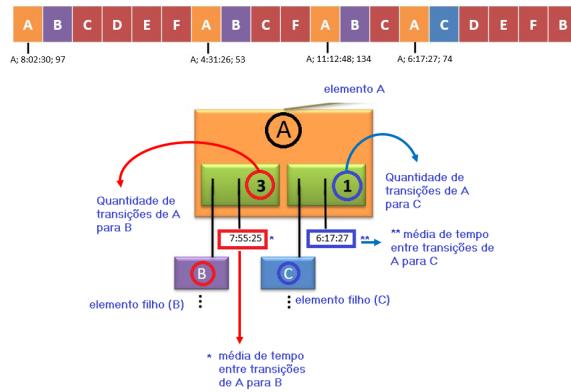


Fig. 3. Exemplo de construção da árvore de predição.

os contextos similares sejam representados por um único identificador e (ii) histórico de contextos contendo os contextos sem repetição sequencial;

- Base de regras de predição: guarda as regras de predição de alerta que o módulo de predição precisa executar.

IV. AVALIAÇÃO E RESULTADOS

Essa seção apresenta os aspectos da implementação do modelo Delfos e como a validação foi realizada. O desenvolvimento contempla os quatro módulos: (i) Módulo de Gerenciamento e Configuração, (ii) Módulo de Predição, (iii) Módulo de Gerenciamento de Perfil e (iv) Módulo de Similaridade de Contextos, assim como todas as funcionalidades do modelo. A avaliação ocorreu em dois cenários de testes, compostos por dados reais: (1) dados de uma distribuidora de energia elétrica; e (2) equipes de futebol do estado do Rio Grande do Sul.

A etapa de implementação contemplou o desenvolvimento que foi realizado com as linguagens de programação C/C++ e Python. A integração das linguagens foi realizada com a ferramenta de software de código aberto Swig. A linguagem Python foi escolhida devido à facilidade que ela apresenta no que diz respeito à análise de dados [18].

Na etapa de análise das cinco bases de dados apresentadas na arquitetura (Fig. 1), foi definida a utilização do banco de dados MongoDB, um banco de dados orientado a documentos, de alto desempenho e escalável. Essa decisão foi baseada no fato do armazenamento de dados de contextos possuir características distintas, para cada tipo de aplicação ou entidade. Cada uma das bases foi implementada como uma coleção distinta do MongoDB, isso devido ao fato do modelo estar sendo executado em uma única máquina e dos testes serem realizados com uma aplicação cliente por vez.

Na fase de implementação foram realizados testes para validação do software. Testes individuais foram aplicados aos quatro módulos e aos *Web services*, e um teste de integração. Após foram realizados testes com dois cenários diferentes, (i) um conjunto de dados de uma distribuidora de energia elétrica, com dados de potência em alimentadores de uma subestação e como isso estava relacionado com a previsão do tempo, e (ii) dados de análise de desempenho de jogadores de futebol, obtidos de equipes participantes de competições do estado do Rio Grande do Sul.




Fig. 4. Configuração do contexto da aplicação da distribuidora de energia elétrica.

Nas avaliações realizadas nos dados foram efetuadas com buscas de perfil e solicitações de predição. Essas buscas foram executadas em momentos diferentes, ou seja, com quantidades de contexto diferentes presentes nas bases de dados do Delfos. Quando realizadas as solicitações de Perfil, o resultado gerado pelo Delfos foi comparado com uma análise da base e avaliado se correto.

A. Cenário 1: Análise do Comportamento da Carga em Relação às Condições Climáticas

O primeiro cenário de avaliação foi construído baseado em um conjunto de dados de curva de carga de seis alimentadores de uma subestação de distribuição de energia elétrica. O conjunto de dados foi obtido junto a um projeto da Pós-graduação em Engenharia Elétrica da Universidade do Vale do Rio dos Sinos juntamente com a distribuidora de energia elétrica, projeto esse aplicado à predição de potência dos alimentadores relacionado com situações climáticas.

A Figura 4 apresenta a representação de contextos da entidade conforme configurado pela aplicação, seguindo o modelo de contextos definido no Delfos (Fig. 2). Como contexto de Identificação da entidade, foi usada a sigla de identificação de um alimentador. Para o contexto de Tempo, foram definidas data e hora. A representação de Localização é composta dos dados de identificação de subestação ao qual o alimentador pertence. Para a situação foram usados os dados de contexto de potência requerida, direção do vento, umidade relativa do ar e nebulosidade.

Na sequência da avaliação foram feitas as atualizações dos históricos de contextos de duas maneiras: (i) inserindo a cada 15 minutos os dados de contextos definidos pela aplicação de maneira a simular a execução do modelo iniciando junto com a aplicação e (ii) o modelo recebendo por mensagem os contextos das entidades referentes a um período de 6 meses.

Após os históricos de contextos serem configurados, foi realizada a configuração das regras de Perfil a serem usadas pelo Delfos. A aplicação foi avaliada para dez grupos de regras de Perfil, o que gerou dez modelos de Perfil diferentes. Foram realizadas solicitações de Perfil para cada modelo, cem vezes, ao longo da execução da avaliação e os aspectos dos Perfis, após validados com o estado atual da base, mostraram um acerto em 100% dos casos para o cenário.

Para exemplificação, de um modelo de regras de perfil usado na validação, foram utilizadas as regras de Tempo igual aos meses de janeiro, fevereiro e março, para Localização de cada subestação específica a Identificação de cada alimentador, e a informação de contexto de Situação igual ao maior valor

de potência. Com isso foi verificado o Perfil referente as demais informações do contexto de Situação, para todos os alimentadores de todas as subestações nos meses citados.

Para a solicitação de predição para o contexto de Tempo, os resultados relacionados ao acerto da predição de contextos das entidades foram de 86% se a solicitação for relacionada às próximas 48 atualizações de contexto, ou seja, até doze horas a frente. Entre o período de 12 e 24 horas a assertividade foi de 72%. No caso da solicitação de predição para o contexto de Localização, os acertos de predição dos contextos de entidades situadas no local e no tempo definidos, foram iguais aos resultados de solicitação de predição para o contexto de Tempo. Essa igualdade se deve aos alimentadores disponíveis na base de dados estarem todos na mesma subestação. Já na solicitação de predição relacionada ao contexto de Identificação, o acerto da predição referente aos dados de contextos da entidade solicitada em um período de tempo definido, foram de 92% se a solicitação for relacionada às próximas doze horas e 87% se for de um período entre 12 e 24 horas à frente do tempo atual.

O último modelo de solicitação a ser testado é relativo ao contexto de Situação. O primeiro tipo de solicitação avaliado diz respeito aos alertas relacionados, ao acerto da predição de dados de contextos das entidades, seguindo a configuração de um valor de contexto de Situação. Neste caso, os acertos foram de 77% em até 24 horas. Um exemplo de teste de solicitação foi o tempo previsto para uma entidade ter o valor de potência maior que um valor especificado na solicitação. Salienta-se que o acerto foi de 90% quando o alerta foi definido para até as próximas 12 horas. Para o segundo tipo de solicitação de contexto de Situação, a assertividade foi de 84% se fossem pedidas todas as entidades para um período de até 12 horas e de 76% para valores de tempo maiores que 12 horas e menores que 24 horas. O acerto aumenta para 88% se a solicitação for feita para uma entidade específica dentro do período de 24 horas.

Acima de 24 horas a média de acertos varia entre 40% e 50% para todos os testes na aplicação da distribuidora de energia elétrica. Esta consideração deve-se ao fato de que a cada nível que o módulo de predição avança na árvore, aumenta o número de probabilidades de valores de dados de contextos futuros. Em ambos os cenários os resultados de interesse de predição são para valores de dados de contextos relativos a atualizações não distantes cronologicamente. Na aplicação da distribuidora de energia elétrica a previsão de tempo é atualizada 3 vezes ao dia e dentro desse espaço a porcentagem de acertos foi de 86% a 92%.

A Figura 5 apresenta um gráfico que mostra a porcentagem de acertos de predição para cada um dos quatro tipos de contextos do Delfos. Nos gráficos a porcentagem é mostrada para os períodos considerados mais significativos na análise dos resultados da avaliação.

B. Cenário 2: Análise de Desempenho de Dileta de Dutsal

Para o segundo cenário de avaliação foram utilizados dois conjuntos de dados relacionados com análise de desempenho de atletas de futsal, os dados foram obtidos junto a analistas




Fig. 5. Gráfico de acertos (%) de predições por tempo na aplicação da distribuidora de energia elétrica.

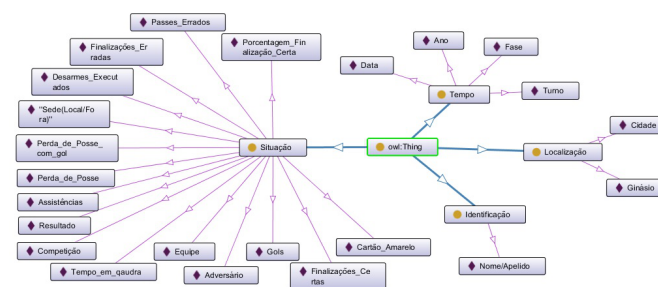


Fig. 6. Configuração do contexto da aplicação de análise de dados de atletas de futsal.

de desempenho de seis equipes de futsal que participam de competições de futsal em nível estadual no Rio Grande do Sul.

A primeira base de dados é composta por dados de análise de desempenho de jogadores de 321 jogos das competições de futsal realizadas no estado do Rio Grande do Sul nos anos de 2017 e 2018. Para cada jogo a base de dados apresenta as informações de 24 atletas (12 em cada equipe).

A Figura 6 apresenta a representação de contexto da entidade conforme configurada pela aplicação seguindo o modelo de contextos definido no Delfos (Fig. 2). Como contexto de Identificação da Entidade, foi usado o nome ou apelido do Atleta. Para contexto de Tempo, foram definidos ano, fase, turno, data e hora da partida. Como representação de localização foram usados os dados de contexto cidade, pois todas as partidas são de competições realizadas no estado do Rio Grande do Sul.

Neste cenário também foram realizados testes com um segundo grupo de dados de movimentação de atletas de uma equipe em um campeonato em 2018, contendo para cada partida os seguintes dados: (i) posição do atleta na quadra, (ii) posse de bola pelo jogador e (iii) ação do jogador.

O primeiro teste foi realizado com o histórico de contextos sendo carregado por partes, recebendo o contexto atual das entidades participantes dos jogos, referentes a uma rodada dos campeonatos por dia. O processo se deu dessa maneira, até que os jogos da temporada de 2019 estivessem ocorrendo, assim, ao final da rodada os contextos atuais eram adicionados ao Delfos.

O segundo teste foi executado repassando os dados de contextos de todos os jogos das temporadas 2017 e 2018

constantes no conjunto. Assim foram adicionados os contextos das entidades relacionados a todos os 262 jogos das séries Ouro e Bronze ocorridos nos anos de 2017 e 2018, gerando um total de 6288 dados de contextos de entidades.

Foram realizadas configurações para futuras solicitações de Perfil. Assim como a avaliação de testes de criação de Perfil realizada para a aplicação da distribuidora de energia elétrica, no segundo cenário para cada uma das análises de dados numéricos e de movimentação dos atletas, foram realizados testes com 10 grupos de regras diferentes e para cada grupo de regras foram realizadas 100 solicitações de Perfil em períodos diferentes de tempo, cujo acerto foi de 100% em comparação com a análise dos dados de contextos das entidades da base.

Em relação à solicitação de predição do primeiro grupo de dados, composto por dados numéricos de análise de desempenho, o modelo não mostrou resultados satisfatórios, isso deve-se ao fato de que os dados ou não apresentam padrão, como chutes a gol por exemplo, ou possuem desvio padrão próximo a 0, como cartões recebidos na partida. Salienta-se que para todos os casos presentes no conjunto de dados, com dados numéricos da análise de desempenho, os dados com valor fora do desvio padrão aconteceram para menos de 20% dos atletas e no máximo dois jogos por atleta. Nesse caso o acerto ficou na ordem de 98%. Portanto, os dados de predição com os dados do primeiro conjunto não foram levados em conta na avaliação geral do modelo.

As solicitações de predição realizadas em relação a segunda base de dados obtiveram resultados significativos em relação a encontrar um padrão de comportamento de movimentação dos atletas durante o jogo. Para a solicitação de predição para o contexto de Tempo os resultados relacionados ao acerto da predição de contextos das entidades, foram de 82% se a solicitação for relacionada às próximas 2 atualizações de contexto, ou seja, até 20 segundos à frente, entre 20 segundos e 1 minuto o acerto caiu para 72%. Considerando-se tempos acima de um minuto os acertos foram na ordem de 50%.

Para a solicitação de predição para o contexto de Localização, os resultados relacionados ao acerto da predição de contextos das entidades localizadas no local e no tempo definido, foram de 92% se a solicitação for relacionada à próxima atualização de contextos (10 segundos), 78% se for entre 20 e 40 segundos à frente do tempo atual. Acima de 40 segundos a média de acerto fica entre 45% e 50%.

No caso da solicitação de predição relacionada ao contexto de Identificação, os resultados foram de 90% se a solicitação for relacionada às próximas atualizações de contexto (10 segundos) e 81% se for um pedido entre 20 e 30 segundos à frente do tempo atual. Acima de 30 segundos a média de acerto fica entre 40% e 50%.

O último modelo de solicitação testado foi relacionado ao contexto de Situação. Essas solicitações se dividem em dois tipos, onde o primeiro tipo, o que solicita alertas, apresentou os resultados de predição de contexto de Situação na ordem de 72% se o período solicitado for de até 30 segundos. Um exemplo de teste desse tipo de solicitação está relacionado ao tempo previsto para uma entidade ter o valor de ação igual a conclusão. Salienta-se que o acerto foi de 87% quando o alerta foi definido para os próximos 10 segundos. Para o




Fig. 7. Gráfico de acertos (%) de predições por tempo na aplicação de movimentação de atletas.

segundo tipo, o que solicita todas as entidades identificadas em um certo período, os acertos foram de 82% se as entidades estiverem em um período de até 20 segundos e entre 72% e 50% para valores de tempo maiores que 20 segundos. O acerto é aumentado para 85% se a solicitação for feita para uma entidade específica dentro do intervalo de 20 segundos.

A Figura 7 apresenta a porcentagem de acerto de predição de contextos diferentes para cada um dos quatro tipos de contextos do Delfos. No gráfico a porcentagem é mostrada para os períodos considerados mais significativos na análise dos resultados da avaliação. A predição de movimento quando realizada no Delfos obteve resultados positivos quando comparada com os processos e técnicas anteriormente utilizados pelos analistas de desempenho das equipes consultadas. O trabalho dos analistas é atualmente realizado com aplicação de planilhas eletrônicas.

V. CONCLUSÃO

Neste artigo foi proposto um modelo computacional para análise multitemporal para sistemas baseados em históricos de contextos. O modelo foi projetado para atender aos requisitos temporais, fazendo uso de históricos de contextos, como forma de permitir ao usuário navegar nas dimensões temporais

Aplicações baseadas em históricos de contextos são cada vez mais comuns, através de sua utilização por tecnologias e metodologias como Internet das Coisas e Sistemas Ciberfísicos, aumentando a inteligência das aplicações por meio de análise multitemporal. Essas aplicações visam funcionar de maneira automatizada e proativa e, nesse ponto, é de interesse possuir dados da dimensão do futuro como proposto no Delfos, predizendo problemas futuros e adaptando o sistema em decorrência dessa predição. Por meio dos testes realizados, pôde-se verificar o suporte às aplicações baseadas em históricos de contextos com variados tipos e quantidades de dados de contextos, para isso foi criado um modelo de contextos com definições básicas que possibilitam sua utilização por aplicações com objetivos diferentes dos apresentados nos cenários avaliados.

Por fim, a discussão teórica e a execução do modelo destacam como trabalhos futuros: (i) a modelagem e implementação da integração com um sistema de Internet das Coisas ou Sistema Ciber-físico; (ii) permitir a utilização de valores de similaridade individuais, para cada dado de contexto da

aplicação; (iii) validar através de técnicas de inteligência artificial, qual é a melhor função de similaridade dentre as possíveis para cada aplicação; e (iv) modelagem e implementação de um módulo de predição baseado em análise de padrões sequenciais e, verificar individualmente, para cada aplicação, qual a melhor técnica a ser usada entre análise de padrões e análise de similaridade numérica.

AGRADECIMENTOS

Os autores agradecem à Fundação de Amparo à Pesquisa do Estado do Rio Grande do Sul (FAPERGS), ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) e à Universidade do Vale do Rio dos Sinos (Unisinos) pelo apoio ao desenvolvimento desse trabalho.

REFERÊNCIAS

- [1] J. H. Rosa, J. L. V. Barbosa, M. Kich, and L. Brito, "A multi-temporal context-aware system for competences management," *International Journal of Artificial Intelligence in Education*, vol. 25, no. 4, pp. 455–492, Dec 2015.
- [2] J. Barbosa, "Multi-temporal aspects on contextual variability modeling," in *Anais do XI Simpósio Brasileiro de Computação Ubíqua e Pervasiva*. Porto Alegre, RS, Brasil: SBC, 2019.
- [3] J. M. Silva, J. H. Rosa, J. L. V. Barbosa, D. N. F. Barbosa, and L. A. M. Palazzo, "Content distribution in trail-aware environments," *Journal of the Brazilian Computer Society*, vol. 16, no. 3, pp. 163–176, Sep 2010.
- [4] A. Wagner, J. L. V. Barbosa, and D. N. F. Barbosa, "A model for profile management applied to ubiquitous learning environments," *Expert Systems with Applications*, vol. 41, no. 4, pp. 2023 – 2034, 2014.
- [5] J. H. da Rosa, J. L. Barbosa, and G. D. Ribeiro, "Oracon: An adaptive model for context prediction," *Expert Systems with Applications*, vol. 45, pp. 56 – 70, 2016.
- [6] C. Voigtmann, S. L. Lau, and K. David, "An approach to collaborative context prediction," in *2011 IEEE International Conference on Pervasive Computing and Communications Workshops (PERCOM Workshops)*, March 2011, pp. 438–443.
- [7] V. Pejovic and M. Musolesi, "Anticipatory mobile computing: A survey of the state of the art and research challenges," *ACM Comput. Surv.*, vol. 47, no. 3, pp. 1–29, Apr. 2015.
- [8] M. Ballings, D. Van den Poel, N. Hespeels, and R. Gryp, "Evaluating multiple classifiers for stock price direction prediction," *Expert Syst. Appl.*, vol. 42, no. 20, pp. 7046–7056, Nov. 2015.
- [9] J. Xu, D. Deng, U. Demiryurek, C. Shahabi, and M. v. d. Schaar, "Context-aware online spatiotemporal traffic prediction," in *2014 IEEE International Conference on Data Mining Workshop*, Dec 2014, pp. 43–46.
- [10] R. Shaptala and A. Kyselova, "Location prediction approach for context-aware energy management system," in *2016 IEEE 36th International Conference on Electronics and Nanotechnology (ELNANO)*, April 2016, pp. 333–336.
- [11] W. Maalej, M. Ellmann, and R. Robbes, "Using contexts similarity to predict relationships between tasks," *Journal of Systems and Software*, vol. 128, pp. 267 – 284, 2017.
- [12] T. K. L. Hui and R. S. Sherratt, "Towards disappearing user interfaces for ubiquitous computing: human enhancement from sixth sense to super senses," *Journal of Ambient Intelligence and Humanized Computing*, vol. 8, no. 3, pp. 449–465, Jun 2017.
- [13] D. Dupont, J. L. V. Barbosa, and B. M. Alves, "Chspam: a multi-domain model for sequential pattern discovery and monitoring in contexts histories," *Pattern Analysis and Applications*, pp. 1–10, Jun 2019.
- [14] A. K. Dey, G. D. Abowd, and D. Salber, "A conceptual framework and a toolkit for supporting the rapid prototyping of context-aware applications," *Hum.-Comput. Interact.*, vol. 16, no. 2, pp. 97–166, Dec. 2001.
- [15] H. Hemmati, A. Arcuri, and L. Briand, "Achieving scalable model-based testing through test case diversity," *ACM Trans. Softw. Eng. Methodol.*, vol. 22, no. 1, pp. 1–42, Mar. 2013.
- [16] S.-H. Cha, "Comprehensive survey on distance/similarity measures between probability density functions," *International Journal of Mathematical Models and Methods in Applied Sciences*, vol. 1, no. 4, pp. 300–307, 2007.

- [17] E. Fredkin, "Trie memory," *Commun. ACM*, vol. 3, no. 9, p. 490–499, Sep. 1960.
- [18] J. Grus, *Data Science from Scratch: First Principles with Python*. Beijing: O'Reilly, 2015.



Márcio Martins é graduado em Ciência da Computação pela UCPEL, mestre em Ciência da Computação pela PUC/RS e doutor em Computação Aplicada pela Universidade do Vale do Rio dos Sinos (UNISINOS). Atualmente é Professor Assistente I na UNISINOS em diversos cursos de graduação e especialização da Escola Politécnica. Possui experiência na área de projeto e desenvolvimento de software, com interesses de pesquisa nas áreas de computação ubíqua, Redes de Computadores e Processamento de Linguagem Natural.



Luan Nesi possui graduação em Jogos e Entretenimento Digital (2011), mestrado (2014) e doutorado (2020) em computação aplicada pela Universidade do Vale do Rio dos Sinos (Unisinos). Atualmente é Pesquisador Assistente II na mesma universidade, atuando junto ao Núcleo de Excelência em Inovação de Software (SoftwareLab). Possui experiência na área de projeto e desenvolvimento de software, com interesses de pesquisa nas áreas de computação ubíqua, meta-heurísticas, inteligência computacional e jogos digitais.



Paulo Pereira Doutor em Engenharia Elétrica pela Universidade Federal de Santa Maria (2014), Mestre em engenharia Elétrica pela Universidade Federal de Santa Maria (2009), graduado em Engenharia Elétrica pela Universidade do Vale do Rio dos Sinos (2004). Tem mais de 15 anos de experiência na área de Engenharia Elétrica, com ênfase no Planejamento e Operação do Sistema de Distribuição. Professor e pesquisador na Escola Politécnica da Universidade do Vale do Rio dos Sinos – UNISINOS. Bolsista de Produtividade do CNPq em Desenvolvimento Tecnológico e Extensão Inovadora DT-2, IEEE-Member e Integrante da equipe da rede de pesquisas sobre geração distribuída, no projeto do Instituto Nacional de Ciência e Tecnologia em Geração Distribuída de Energia Elétrica (INCT-GD).



Jorge Barbosa possui graduação em Informática e Engenharia Elétrica pela Universidade Católica de Pelotas (UCPEL). Ele obteve especialização em Engenharia de Software (UCPEL) e concluiu mestrado e doutorado em ciência da computação na Universidade Federal do Rio Grande do Sul (UFRGS). Em 2011 realizou pós-doutorado na Sungkyunkwan University (SKKU, Suwon, Coréia do Sul). Em 2020 realizou um segundo pós-doutorado na University of California – Irvine (UCI, Irvine, EUA). Atualmente é Professor Titular II na Universidade do Vale do Rio dos Sinos (Unisinos). Ele atua no Programa de Pós-graduação em Computação Aplicada (PPGCA) e no Programa de Pós-graduação em Engenharia Elétrica (PPGEE). Jorge coordena o Laboratório de Computação Móvel e Ubíqua (MobiLab) e atua como Bolsista de Produtividade em Desenvolvimento Tecnológico e Extensão Inovadora (bolsa DT - atualmente no Nível IC) do CNPq. Recentemente, ele foi indicado pelo Conselho Deliberativo (CD) do CNPq para compor o Comitê de Assessoramento de Bolsas de Produtividade em Desenvolvimento Tecnológico e Extensão Inovadora (CA-DT).