

Análise de uma Rede Neural Híbrida como base para um Mecanismo de Predição de Situação

Carlos O. Rolim, Anubis Rossetto, Valderi R. Q. Leithardt, Cláudio F. R. Geyer

Instituto de Informática – Universidade Federal do Rio Grande do Sul (UFRGS)
Caixa Postal 15.064 – 91.501-970 – Porto Alegre – RS – Brazil

{carlos.oberdan,anubis.rossetto,valderi.quietinho,geyer}@inf.ufrgs.br

Abstract. *This paper presents the results towards a technique that can be used as an underlying mechanism for situational prediction. We analyzed a hybrid neural network called Multioutput Adaptive Neural Fuzzy Inference System (MANFIS) and its predictive ability was compared with a Multi Layer Perceptron (MLP). The results demonstrate that depending of application the use of neural networks can be considered a good approach for the situational prediction when combined with other techniques.*

Resumo. *Este artigo possui como foco apresentar os resultados da busca de uma técnica que possa ser utilizada como base em um mecanismo de predição de Situação voltado para Inteligência Ambiental. Foi analisado o uso de uma rede neural híbrida chamada de Multioutput Adaptative Neural Fuzzy Inference System (MANFIS) e então sua capacidade preditiva foi comparada com uma rede Multi Layer Perceptron (MLP). Os resultados demonstram que dependendo do tipo de aplicação o uso de redes neurais pode ser considerado uma boa alternativa para predição de situação quando combinadas com outras técnicas.*

1. Introdução

A computação ubíqua e pervasiva (ou ubicomp) têm sido o foco de diversos pesquisadores que buscam desenvolver ambientes dotados de certo grau de inteligência, capazes de reger a atuação de dispositivos e aplicações de forma autônoma, de acordo com as necessidades dos usuários. Nessa área de aplicação da ubicomp são empregados os conceitos de **Inteligência Ambiental** - do inglês *Ambient Intelligence* ou AmI [Augusto, Juan Carlos and Shapiro 2007; Ramos et al. 2008; Cook et al. 2009;] e **Ambientes Inteligentes** - também chamados de espaços inteligentes, espaços pervasivos ou ambientes reativos [Alves, Lino et al. 2010]. Embora ambos os conceitos estejam extremamente relacionados pode-se distingui-los pela metáfora da “mente/cérebro” usada em IA. O primeiro é mais focado em técnicas para fazer o ambiente possuir um comportamento inteligente (algoritmos, técnicas, etc.), enquanto o segundo é mais relacionado ao controle dos dispositivos, a interconexão de forma inteligente de recursos e seu comportamento coletivo (Buchmayr & Kurschl, 2011).

Os produtos, serviços e aplicações que surgem com o uso destes conceitos emergentes da área de computação ubíqua e pervasiva envolvem a automação de ambientes em diversos níveis, indo desde um simples cômodo de uma residência, prestando serviços de forma inteligente aos moradores locais, chegando a atingir até mesmo uma cidade inteira, onde os habitantes possuem suas atividades diárias auxiliadas por serviços computacionais personalizados. Uma característica desses ambientes é o dinamismo, de forma que as aplicações não possuem um comportamento determinístico, mas sim dependente do contexto que se apresenta. As aplicações precisam então

compreender a necessidade dos usuários e a seguir orquestrar recursos para que os serviços sejam prestados da melhor forma possível (Zaidenberg, Reignier 2008). Isso somente é viável através de constante monitoramento e interação com o ambiente onde os usuários estão, de forma que novos conhecimentos sobre os mesmos possam ser descobertos visando adaptações de contexto (Bhatt, 2009). Entretanto, as informações de contexto utilizadas pelas aplicações quando obtidas a partir de dados de sensores de baixo-nível sem maiores interpretações podem não ter significados, serem triviais ou vulneráveis a pequenas mudanças ou incertezas. As limitações dessas informações de baixo-nível acontecem quando se torna necessário modelar o comportamento de diferentes entidades existentes em um ambiente e seus relacionamentos. Uma forma de contornar esse problema é derivar informações de contexto a partir dos valores de baixo-nível criando uma nova camada de alto-nível que consiga capturar as percepções dos sensores como entradas para disparar ações no sistema. Na literatura diferentes noções têm sido empregadas para definir essa camada de alto-nível de representação do contexto. Os termos mais usados são contexto situacional (Gellersen, Schmidt, & Beigl, 2002), sensibilidade à situação [Endsley and Connors 2008; Endsley 2006] e situação (Dey, 2001). A noção de situação é usada como um conceito de alto-nível para representação de estado e é a base para a definição de uma visão holística da consciência de contexto chamada de consciência de situação (do inglês *situation awareness* ou *SAW*).

A partir desta premissa, autores como Buchmayr (Buchmayr & Kurschl, 2011) e Ye (Ye, Dobson, & McKeever, 2011) focaram suas pesquisas na direção de como aplicar a consciência de situação em Inteligência Ambiental. Entre suas conclusões, ambos foram enfáticos em demonstrar que os trabalhos desenvolvidos nessa área ainda possuem carências em questões de representação das primitivas de situações, das especificações lógicas das situações, de assuntos relacionados ao raciocínio e à tomada de decisão. Além destas, destacam também que as soluções propostas não possuem mecanismos de predição de situações futuras que possibilitem analisar os impactos que as ações tomadas irão gerar no ambiente e como essas ações devem ser executadas de forma a levar em consideração as necessidades do usuário. Ou seja, as aplicações e serviços desenvolvidos hoje são capazes de se adaptarem ao contexto momentâneo no qual estão inseridos e até conseguem inferir a respeito da situação **atual** do usuário (visão de alto-nível). Porém, possuem dificuldades em orquestrar recursos que serão necessários para atender as demandas de uma situação **futura**, pois não possuem mecanismos preditivos capazes de auxiliarem as aplicações na tomada de decisões de adaptação de contexto. A possibilidade de predição de situações proporciona que os serviços sejam prestados com maior invisibilidade e pró-atividade, indo ao encontro das idéias de Mark Weiser (considerado pai da ubicomp).

Assim, o desenvolvimento de uma solução computacional que além de executar a inferência de situações também possibilite a predição parece ser a alternativa para os problemas apontados acima relacionados à Inteligência Ambiental. Nesse sentido, acredita-se que uma rede neural possa ser usada como técnica base em um mecanismo de predição dessa solução, pois a mesma é capaz de inferir a respeito dos dados de contexto de baixo nível, aprender com eles e então predizer os valores que irão compor uma situação futura. Dessa forma, esse trabalho tem por objetivo demonstrar os resultados preliminares da capacidade preditiva de uma rede neural híbrida chamada de *Multioutput Adaptive Neural Fuzzy Inference System* (MANFIS) quando aplicada na predição de dados que caracterizam uma situação. Para fins de análise com técnicas semelhantes é efetuado um comparativo entre um MANFIS e um *Multi Layer Perceptron* (MLP). Ressalta-se que o foco aqui está somente na análise da capacidade preditiva do MANFIS e da possibilidade de usá-lo como técnica base para o mecanismo de predição. As questões gerais de

desenvolvimento da solução computacional (como modelagem de situação, inferência, fusão de dados, incerteza, *etc*) estão fora do escopo desse trabalho.

A principal contribuição deste trabalho ao estado da arte está na análise da viabilidade de uso de uma rede neural híbrida como técnica base para um mecanismo de predição de situação. Os resultados dessa análise comparativa do MANFIS com MLP aplicados na Inteligência Ambiental, além de serem originais, servem como rumo para que novas pesquisas na área sejam desenvolvidas.

O trabalho está organizado da seguinte forma: na seção 2 são apresentados os conceitos de consciência de situação e as abordagens para sua predição e raciocínio; na seção 3 é caracterizado o mecanismo de predição e a motivação de uso de um MANFIS como técnica base para seu desenvolvimento; a seção 4 demonstra os resultados experimentais do uso do MANFIS na predição de dados de situação comparando a sua performance com um MLP; a seção 5 faz uma análise dos trabalhos relacionados e; finalmente as conclusões e trabalhos futuros são apresentados na seção 6.

2. Consciência de situação

Antes de falar sobre consciência de situação é necessário definir situação. Para Yau (Yau, Huang, Gong, & Science, 2004; Yau, Wang, Karim, & Science, 2002) “situação é um conjunto de contextos relevantes para uma aplicação em um período de tempo que afetam o comportamento futuro do sistema”. De forma mais atual Bettini (Bettini et al., 2010) define que situação é um conjunto de abstrações semânticas obtidas a partir de partes de informações de baixo-nível, conhecimento humano e interpretações do mundo. Já Ye (Ye et al., 2011) define situação como uma abstração de eventos ocorrendo no mundo real derivada de contextos e hipóteses sobre como os contextos observados são relacionados aos fatos de interesses do projetista e da aplicação. Computacionalmente falando, pode-se definir que uma situação é um estado particular que é abstraído dos dados dos sensores e é de interesse da aplicação, de forma que certas ações podem ser tomadas quando a situação está acontecendo. Ou seja, pode-se dizer que a noção de situação é usada como um conceito de alto-nível para representação de estado.

As aplicações que utilizam técnicas de sensibilidade à situação são conhecidas como aplicações conscientes de situação (*situation awareness* ou SA). Para essas aplicações, as situações são interpretações semânticas externas de contexto de baixo nível, permitindo uma especificação de alto-nível do comportamento humano e da sua interação com o sistema. Situações injetam significado às aplicações, são mais estáveis e mais fáceis de definir e manter do que informações contextuais básicas. Adaptações em aplicações sensíveis ao contexto são então causadas por mudanças nas situações (por exemplo, a mudança de um valor de contexto dispara uma adaptação se a atualização de contexto alterar a situação). O projeto dessas aplicações torna-se muito mais fácil, pois o projetista pode operar em alto nível de abstração (situação) e não em todas as pequenas informações de contexto que criam a situação.

A grande vantagem de usar situações está na habilidade de proporcionar uma representação compreensível pelos humanos dos dados dos sensores para as aplicações, enquanto se abstrai delas a complexidade de leitura dos dados, de ruídos nestes dados e das atividades de inferência (Ye et al., 2011). O que distingue uma situação de uma atividade e reconhecimento de situação de reconhecimento de atividade é a inclusão de uma situação em aspectos temporais e estruturais, incluindo hora do dia, duração, frequência, etc. Uma situação pode ser simples, como um estado abstrato de uma certa entidade (por exemplo, a

sala está ocupada) ou uma ação humana que acontece em um local (exemplo, trabalhando ou cozinhando).

2.1. Raciocínio e predição de situação

Para que a Inteligência Ambiental seja realmente efetiva os sistemas devem ser capazes de raciocinar e prever sobre as informações de contexto. Isso acaba envolvendo também a fase de identificação dos dados que caracterizam determinado contexto. Diversas técnicas são estudadas por pesquisadores, entretanto são poucos os trabalhos que usam a representação de mais alto nível de contexto chamada de situação. Segundo o excelente trabalho de Ye (Ye et al., 2011), as técnicas de raciocínio e predição de situação mais promissoras são aquelas consideradas híbridas, que utilizam **abordagens baseadas em especificações** juntamente com as **abordagens baseadas em aprendizado**. As abordagens baseadas em especificação são utilizadas em situações simples, com poucos sensores, com informações precisas e que podem usar o conhecimento do especialista através de regras lógicas para representar as situações; o uso de raciocínio é somente utilizado para inferir a respeito de situações a partir das entradas dos sensores. Já as **abordagens baseadas em aprendizado** são aquelas que visam ser aplicadas em ambientes onde existe uma grande quantidade de sensores, coletando dados diversos (os quais muitas vezes podem ser imprecisos ou conflitantes) e que podem caracterizar atividades e situações complexas. Nesses ambientes se torna pouco flexível, ou até mesmo impossível, usar somente o conhecimento de especialistas para especificar de forma apropriada as situações que podem acontecer. A figura 1 sintetiza essas abordagens de acordo com as técnicas empregadas e o seu relacionamento com o aumento da complexidade do problema.

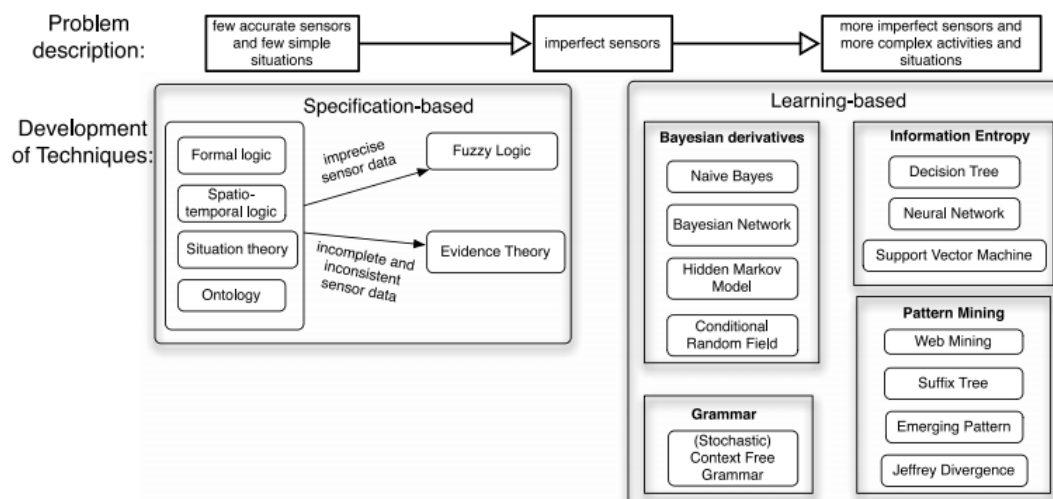


Figura 1. Técnicas de raciocínio de situações e sua relação com ao aumento da complexidade do problema (Ye et al., 2011)

Outro apontamento feito pelos autores é a carência de uma solução que seja capaz de prever situações. Com base nisso, os autores deste trabalho estão trabalhando no desenvolvimento de um mecanismo que consiga prever dados que provavelmente caracterizarão situações futuras. Esse mecanismo de predição é uma pequena parte de uma solução computacional híbrida (que utiliza abordagens baseadas em especificação e em aprendizado) e que é capaz de lidar com questões relacionadas à consciência de situação, chamada de Gerenciador de Situação. Tal Gerenciador de Situação terá suas

funcionalidades descritas em trabalhos futuros. A próxima seção visa demonstrar aspectos conceituais envolvidos na predição de situação usando redes neurais.

3. Predição usando Redes Neurais

O mecanismo de predição de situação tem a finalidade de predizer dados de contexto que provavelmente irão compor situações futuras. Ele infere a respeito dos dados de contexto de baixo nível (obtidos a partir de sensores) que caracterizam uma situação, e com base no conhecimento adquirido fornece na saída novos dados que compõem uma situação futura. Estes dados podem ser utilizados pelas aplicações para adaptações de contexto e tomadas de decisão. Pode-se imaginar que ele seja uma pequena “caixa-preta” capaz de ser implementada como um módulo “*plugável*” em *middlewares* maiores como, por exemplo, o Percontrol [Leithardt, V. R. Q. et al. 2012], o EXEHDA (Yamin, 2004), o Continuum (Costa, 2008) ou então disponibilizado como um serviço em alguma plataforma de ubiomp baseada em SOA (*Service Oriented Architecture*).

Com base na seção anterior, esse mecanismo de predição pode ser construído utilizando uma abordagem baseada em aprendizado uma vez que ele precisa ser capaz de lidar com dados históricos de forma a aprender a respeito de situações futuras. Devido à natureza probabilística do mecanismo e a sua necessidade de aprendizagem foi escolhida uma rede neural como técnica base no seu desenvolvimento. As redes neurais são estruturas computacionais que empregam modelos matemáticos para representar comportamento inteligente, capaz de aprender através da experiência. Existem diversos tipos de redes neurais, um tipo comumente utilizado é o Perceptron Muti Camadas (MLP, do inglês *Multi-Layer Perceptron* MLP). Um MLP é formado de três ou mais camadas (uma camada de entrada, uma camada de saída e uma ou mais camadas ocultas). Um problema comum apontado para esse tipo de rede é a natureza “caixa-preta” (Haykin, 2011). Isso pode ser atribuído à dificuldade de entender e compreender o funcionamento interno da rede. Outro ponto criticado é o esforço necessário para ajustar e selecionar a melhor configuração da rede.

A alternativa para esses dois problema é ter uma rede que seja capaz de “aprender” a respeito dos dados e representar o conhecimento de uma forma mais “humana”. Uma abordagem utilizada é combinar lógica *fuzzy* com redes neurais para construir uma rede híbrida. Dessa forma, cada neurônio da rede implementa um conjunto fuzzy e então a rede ajusta as suas funções de pertinência através de mecanismos matemáticos internos baseando-se nos dados fornecidos na fase de treinamento. Diferentes tipos de redes tem sido construídas para implementar os modelos de inferência fuzzy de Mandani e de Takagi Sugeno, como por exemplo FALCON, ANFIS, NEFCON, NEFCLASS, NEFPROX, FUN, SONFIN, EFuNN e outros (Abraham, 2005). No geral o modelo de Takagi-Sugeno possui menor erro médio quadrático (RMSE) e produz sistemas mais precisos que os sistemas que implementam o modelo Mamdani, o qual é mais rápido que o primeiro (Marza & Teshnehlab, 2009). Entretanto, como a predição demanda precisão, não serão considerados modelos como FALCON, NEFCON, NEFCLASS e EfuNN, ou mesmo FUN, que não utilizam técnicas formais de aprendizagem (é randomizado um valor para ser usado nas funções de pertinências). No que diz respeito a outros modelos, Mackey (Mackey & Glass, 1977) efetuou um comparativo de performance sobre alguns sistemas neuro-fuzzy na predição de séries temporais caóticas e demonstrou que um ANFIS possui menor RMSE que NEFPROX, SOFIN e dmEFuNN que usam o modelo Takagi-Sugeno.

Dessa forma a escolha foi o uso de ANFIS para predição. Entretanto para ser aplicada na predição de valores de baixo nível que formam uma situação, a rede deve

fornecer mais de um valor na saída. Uma rede ANFIS fornece somente uma saída. Por essa razão a decisão foi utilizar um *Multioutput Adaptive Neural Fuzzy Inference System* (Benmiloud, 2010) que é uma extensão da *Adaptive Neural Fuzzy System* (ANFIS) (Jang, 1993). Como o próprio nome diz MANFIS funciona como vários ANFIS interconectados proporcionando múltiplas saídas ao invés de somente uma como acontece no ANFIS. Assim como no caso do ANFIS, o potencial do MANFIS está na sua habilidade de construir o mapeamento de entrada-saída usando conhecimento humano (na forma de regras *fuzzy if-then*) e no aprendizado dos dados fornecidos. Isso é possível, pois cada neurônio do MANFIS implementa um conjunto *fuzzy*. A rede ajusta as funções de pertinência usadas através de mecanismos de inferência *fuzzy* internos baseando-se nos dados proporcionados na fase de treinamento. Para ajustar os parâmetros das funções de pertinência é utilizado um vetor de gradientes, o qual mensura a inferência do sistema através de um conjunto de regras buscando reduzir o erro global. O ajuste dos pesos é efetuado através de um algoritmo híbrido em dois passos (ou fases) que combina os métodos de *Least-Square Estimator* (LSE) e *Gradient Descent* (GD). Essa abordagem híbrida proporciona que a convergência da rede aconteça de forma mais rápida uma vez que as dimensões do espaço de busca são reduzidas em relação ao método original utilizado no algoritmo de *backpropagation*. No caso do MANFIS o algoritmo precisa ser adaptado para trabalhar com múltiplas saídas ao invés de somente uma como acontece no ANFIS.

Após a explicação dos fatores que determinaram a escolha de um MANFIS e demonstraram suas características, na próxima seção serão apresentados os resultados que demonstram o comportamento do MANFIS como técnica base para predição de situações.

4. Resultados experimentais

O desenvolvimento de uma rede neural basicamente envolve os seguintes passos: definir a entrada e saída dos dados, configurar a rede, treiná-la, testá-la e então validá-la. O experimento realizado visou verificar o poder de predição de um MANFIS e compará-lo com uma MLP. Foram utilizados os dados disponibilizados publicamente pelo projeto CARE (*Context Awareness in Residence for Elders*) apresentados no trabalho de Kasteren (Kasteren et al., 2010). Os dados utilizados representam o estado de 14 sensores dispostos em uma residência de um morador e coletados em segmentos de tempo de 60 segundos. No caso do artigo original foram aplicados métodos probabilísticos (cadeias ocultas de Markov – HMM – e Campos Aleatórios Condicionais – CRF) para identificar o reconhecimento de atividades no ambiente. No caso do presente trabalho os dados dos sensores e *timestamp* de suas coletas foram utilizados como entrada dos diferentes modelos de redes e então verificado se eles seriam capazes de predizer o próximo estado destes sensores. Ou seja, uma vez que se consegue predizer corretamente o estado seguinte dos sensores se consegue caracterizar a atividade que provavelmente será desenvolvida e então inferir a respeito da situação envolvida nessa atividade. Do conjunto de dados disponibilizados foram utilizadas 2000 entradas para treinamento e 2000 foram usadas para validação das redes através do método de validação cruzada múltipla (*10-fold cross-validation*).

A primeira rede analisada foi a MLP, construída com o uso do Matlab e do Neural Network Toolbox. Após testes e validação através da matriz de confusão, a melhor topologia foi formada por 15 nodos de entrada, uma camada oculta com 5 nodos usando a tangente hiperbólica como função de ativação e 14 nodos na saída representando os valores preditos (status de cada sensor). A taxa de aprendizagem μ utilizada foi $1e^{-5}$. Com essa

configuração o erro quadrático médio (MSE) foi de 0.0063 (RMSE=0.0794) após 90 épocas de treinamento (Figura 2 a).

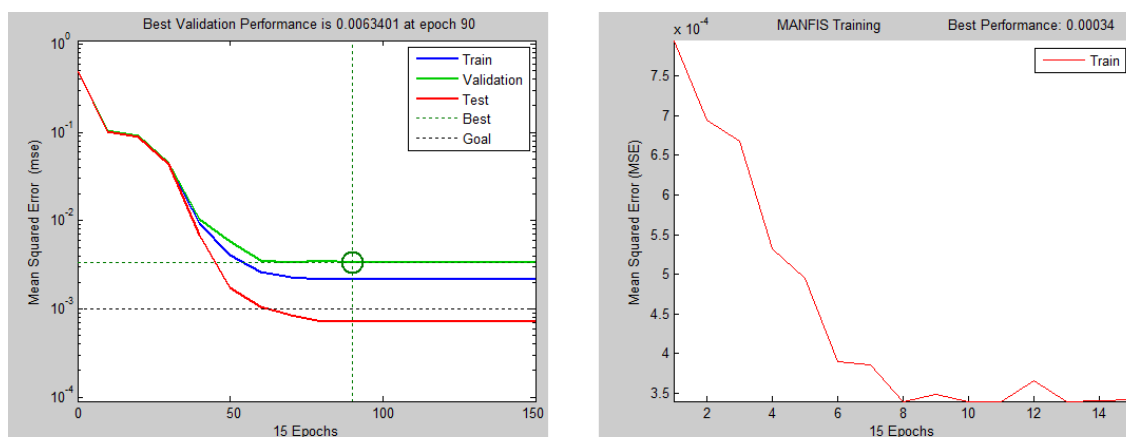


Figura 2. (a) Performance do MLP

(b) Performance do MANFIS

O MANFIS também foi construído no Matlab, testado e validado da mesma forma que o MLP. Como esperado não foi necessária muita intervenção manual. Isso se deve ao fato de que os parâmetros de configuração são ajustados por funções matemáticas internas com base nos dados de entrada. Entretanto, ainda foi necessário selecionar o melhor método de particionamento do espaço de entrada. No caso desse trabalho, devido ao número de variáveis de entrada não foi possível utilizar o particionamento em grade (*grid partition*) como método de particionamento (ele gera regras enumerando todas as possíveis combinações das funções de pertinência para todas as entradas e isso gera uma explosão exponencial de regras). Por isso, foi selecionado o método de agrupamento subtrativo (*subtractive clustering*) que produz um particionamento espalhado (*scattering partition*). Com isso são utilizados poucos recursos computacionais devido ao reduzido número de regras geradas. Nesse caso, a única informação necessária é o grau de influência do centro do cluster para cada uma das dimensões de entrada e saída, supondo que os dados estejam dentro de um hipercubo unitário (intervalo [0 1]). Se o raio do cluster for pequeno, serão gerados vários pequenos clusters de dados e isso resultará em mais regras. Após a construção da matriz de confusão a melhor configuração foi obtida com cluster de raio igual a 0.25 em cada uma das entradas. Com essa configuração o erro quadrático médio (MSE) resultante foi de 0.00034 (RMSE=0.0185), (Figura 2 b) em contraste com os 0.0063 do MLP. O número total de regras geradas no espaço de particionamento foi de 7 para cada uma das 14 entradas, totalizando 98 regras (nos testes efetuados usando *grid partition* com 3 funções de pertinência para cada uma das 14 entradas o total foi de 3^{14} , ou seja, absurdas 4.782.969 regras). Se for reduzido o valor do raio do cluster, o número de regras e o tempo necessário para calcular as regras crescem drasticamente juntamente com o aumento no consumo dos recursos computacionais. Nesse caso, seria necessário reduzir o conjunto de dados de treinamento, o que também reduziria o poder de generalização da rede. Também pode ser verificado que o MANFIS além de possuir um RMSE menor, comparado ao MLP, convergiu mais rapidamente demonstrando a sua facilidade de aprendizado de padrões.

Os resultados dos experimentos demonstram que um MLP consegue prever corretamente os valores de contexto que caracterizam determinada situação. Entretanto ele requer maior intervenção manual para configurar os parâmetros e diversos procedimentos de execução/teste para se chegar a uma configuração satisfatória. Já o MANFIS não demanda muita intervenção manual. Somente foram ajustados alguns parâmetros

relacionados à clusterização dos dados e a rede fez o resto por si. Apesar dessa pouca intervenção os resultados preditivos do MANFIS foram mais exatos que o MLP e a sua convergência aconteceu de forma mais rápida, porém foram utilizados mais recursos computacionais em relação ao MLP. Pode-se observar também que o MANFIS foi capaz de alcançar um RMSE aceitável em testes onde foram reduzidas as quantidades de valores no conjunto de treinamento. Isso é interessante em Inteligência Ambiental uma vez que não se precisa monitorar o ambiente durante muito tempo para definir um padrão de comportamento. Entretanto deve-se tomar cuidado para que os valores de máxima e de mínima no universo de discurso estejam representados, senão o poder de generalização da rede será degradado. Em resumo, ambos os modelos aprenderam a respeito do comportamento dos sensores no ambiente e a partir dos dados de entrada conseguiram prever novos dados de saída que representam prováveis situações futuras. Segundo os testes efetuados, o MANFIS possui melhor capacidade preditiva que um MLP quando aplicado na predição de dados de contexto e requer menos esforços de configuração e treinamento, porém em troca existe maior uso de processamento. Ou seja, o MANFIS parece ser uma boa abordagem para ser usado como técnica base para o Mecanismo de Predição de Situação. Porém, em ambientes com grande dinamismo (onde padrões de dados mudam constantemente) será necessário o constante retreinamento do sistema para se adequar aos novos padrões (recalibragem) e isso também vai demandar novo custo de processamento. Dependendo do tipo de aplicação, essa característica pode inviabilizar o uso do MANFIS. Uma solução é combiná-lo com outra técnica apresentada na figura 2.1 ou então verificar a possibilidade de uso de uma rede com aprendizagem não supervisionada.

5. Trabalhos relacionados

Essa seção traz somente os trabalhos relacionados a técnicas de aprendizagem de máquina voltadas para predição de contexto. O Grupo de Pesquisa em Computação Pervasiva da Universidade de Atenas na Grécia vêm desenvolvendo há alguns anos trabalhos de predição de localização de usuários usando técnicas de aprendizagem de máquina [Anagnostopoulos, T. et al. 2007; Anagnostopoulos, T. et al. 2009]. Nos trabalhos mais recentes do grupo pode-se citar Anagnostopoulos [Anagnostopoulos, T. et al. 2009], onde é demonstrado um comparativo entre uma rede neural ART (Adaptative Resonance Theory) com um algoritmo on-line e off-line de clusterização k-Means com o uso da distância de Hausdorff para cálculo de vizinhança disjunta. Segundo os autores essa proposta apesar de ser promissora acaba respondendo de forma lenta a mudanças nos padrões e não proporciona adaptações para padrões de mobilidade não vistas previamente. Além disso, demanda muito espaço para armazenamento de dados. Isso acabou levando os autores a desenvolverem outro trabalho que fosse capaz de responder rapidamente às mudanças, ter curto conhecimento espaço-temporal do padrão de mobilidade do usuário e utilizar baixo requerimento para manipulação e armazenamento dos dados de históricos de movimentos dos usuários. A alternativa desenvolvida foi uma memória adaptativa curta para predição com o uso de um controlador *fuzzy* (T. Anagnostopoulos, Anagnostopoulos, & Hadjiefthymiades, 2011). Ambos os trabalhos demonstram os esforços de um grupo no desenvolvimento de predição usando técnicas de aprendizagem de máquina como o trabalho corrente, porém o foco é somente em questão de localização e não na abstração de alto nível de situação como o desejado. O trabalho de Benta (K.-I. Benta, Cremene, & Todica, 2009; K.-I. Benta, Hoszu, Văcariu, & Creț, 2009; K.-iulian Benta et al., 2010) apresenta o uso de uma rede MLP capaz de aprender o comportamento do usuário, tomar decisões a respeito de modificações no ambiente e então avaliar a satisfação dos usuários a

partir do reconhecimento facial dos usuários. O interessante desse trabalho é que apesar dele fazer uso de ontologias, ele é capaz de aprender novas preferências, incorporando-as à base de regras. Sua limitação deve-se ao fato de não possuir mecanismos diretos de predição de situação, sendo na maior parte das vezes somente reativo às alterações que acontecem. O artigo de Elmahalawy (Elmahalawy, Elfishawy, & El-dien, 2010) apresenta a construção de um simulador chamado de *Power Management in Smart Home Product* (PMSHP). Esse simulador é voltado para predições de questões energéticas em um Ambiente Inteligente através do uso de Algoritmos Evolutivos (AE). A ideia do uso de AE é interessante e merece maiores investigações para sua aplicação em predição de contextos.

Essas são algumas iniciativas diretamente relacionadas ao escopo desse trabalho. Como se percebe nenhuma delas possui foco em questões preditivas, não propondo um novo método ou mesmo aplicando alguma técnica existente como aqui está sendo feito. Dessa forma, a análise que foi efetuada demonstra uma possibilidade inovadora e original, em um tópico que possui diversos desafios a serem superados pela comunidade acadêmica.

6. Conclusões e rumos futuros

Esse trabalho efetuou a análise da capacidade preditiva de uma rede neural híbrida chamada MANFIS buscando verificar se a mesma pode ser utilizada como técnica base para um mecanismo de predição de situação. Os resultados demonstraram que um MANFIS possui menor erro de predição e convergência mais rápida em relação a uma rede MLP. Entretanto um MANFIS consome mais recursos computacionais de processamento e carece de mecanismos matemáticos que permitam que seus parâmetros de configuração sejam ajustados em tempo de execução, o que é importante em ambientes extremamente dinâmicos, onde os padrões de dados mudam frequentemente ou que exijam processamento em tempo real sem a possibilidade de treinamento prévio. Ou seja, pode-se concluir que um MANFIS pode ser utilizado como técnica base para o Mecanismo de Predição de Situação desde que seja combinado com alguma outra técnica que contorne esse problema de ajuste de configuração em tempo real. O ideal seria combiná-lo com outra abordagem baseada em aprendizagem de máquina ou mineração de dados. Caso isso não seja possível e a aplicação exija processamento em tempo real sem treinamento prévio, o melhor é usar uma rede com aprendizagem não supervisionada ao invés do MANFIS.

Como trabalhos futuros estão a análise dessa outra técnica que poderá ser combinada com o MANFIS e também maiores estudos visando predizer não apenas as informações que caracterizam o estado seguinte dos sensores e sim os próximos N estados, o que sem dúvida melhoraria a adaptação de contexto das aplicações.

7. Referências

- Abraham, A. (2005). Adaptation of Fuzzy Inference System Using Neural Learning. *Architecture*, 83, 53- 83.
- Alves Lino, J., Salem, B., & Rauterberg, M. (2010). Responsive environments: User experiences for ambient intelligence. *Journal of Ambient*, 2(4), 347–367. IOS Press. doi:10.3233/AIS-2010-0080
- Anagnostopoulos, T., Anagnostopoulos, C. B., Hadjiefthymiades, S., Kalousis, A., & Kyriakakos, M. (2007). Path Prediction through Data Mining. *Artificial Intelligence*, 128-135. IEEE.
- Anagnostopoulos, T., Anagnostopoulos, C., & Hadjiefthymiades, S. (2009). An Online Adaptive Model for Location Prediction. *Autonomics '09* (pp. 64-78).
- Anagnostopoulos, T., Anagnostopoulos, C., & Hadjiefthymiades, S. (2011). An adaptive location prediction model based on fuzzy control. *Computer Communications*, 34(7), 816-834.
- Anagnostopoulos, T., Anagnostopoulos, C., Hadjiefthymiades, S., Kyriakakos, M., & Kalousis, A. (2009). Predicting the location of mobile users: a machine learning approach. *Proceedings of the 2009 international conference on Pervasive services* (pp. 65-72). ACM. doi:10.1145/1568199.1568210

- Augusto, Juan Carlos, & Shapiro, D. (2007). Notes from editors. *Frontiers in Artificial Intelligence and Applications*, 164.
- Benmiloud, T. (2010). Multioutput adaptive neuro-fuzzy inference system. In *11th WSEAS international conference on neural networks* (pp. 94-98). Stevens Point, Wisconsin, USA: World Scientific and Engineering Academy and Society (WSEAS).
- Benta, K.-I., Cremene, M., & Todica, V. (2009). Towards an Affective Aware Home. *Proceedings of the ICOST* (pp. 74-81).
- Benta, K.-I., Hoszu, A., Văcariu, L., & Creț, O. (2009). Agent based smart house platform with affective control. *Proceedings of the 2009 Euro American Conference on Telematics and Information Systems New Opportunities to increase Digital Citizenship*, 1-7. ACM Press. doi:10.1145/1551722.1551740
- Benta, K.-I., Cremene, M., Hoszu, A., Editors, M., Margaria, T., Padberg, J., & Taentzer, G. (2010). Training the Behaviour Preferences on Context Changes. *ECEASST*, 28.
- Bettini, C., Brdiczka, O., Henricksen, K., Indulska, J., Nicklas, D., Ranganathan, A., & Riboni, D. (2010). A survey of context modelling and reasoning techniques. *Pervasive and Mobile Comp.*, 6(2), 161-180.
- Buchmayr, M., & Kurschl, W. (2011). A survey on situation-aware ambient intelligence systems. *Journal of Ambient Intelligence and Humanized Computing*, 2(3), 175-183. doi:10.1007/s12652-011-0055-1
- Cook, D. J., Augusto, J. C., & Jakkula, V. R. (2009). Ambient intelligence: applications in society and opportunities for artificial intelligence. *Pervasive and Mobile Computing*.
- Costa, C. A. (2008). *Continuum: A Context-aware Service-based Software Infrastructure for Ubiquitous Computing*. UFRGS.
- Dey, A. K. (2001). Understanding and Using Context. (A. K. Dey, G. Kortüm, D. R. Morse, & A. Schmidt, Eds.) *Personal and Ubiquitous Computing*, 5(1), 4-7. Springer-Verlag. doi:10.1007/s007790170019
- Elmahalawy, A. M., Elfishawy, N., & El-dien, M. N. (2010). Anticipation the consumed electrical power in Smart Home using evolutionary algorithms. *2010 International Conference on Multimedia Computing and Information Technology MCIT*, 81-84. Ieee. doi:10.1109/MCIT.2010.5444847
- Endsley, M. R. (2006). Situation Awareness. In G. Salvendy (Ed.), *Handbook of Human Factors and Ergonomics* (pp. 528-542). John Wiley & Sons Ltd. doi:10.1002/0470048204.ch20
- Endsley, M. R., & Connors, E. S. (2008). Situation Awareness: State of the Art. *Energy*, 13-16.
- Gellersen, H., Schmidt, A., & Beigl, M. (2002). Multi-Sensor Context-Awareness in Mobile Devices and Smart Artefacts. *Mobile Networks and Applications*, 7(5), 341-351. Kluwer Academic Publishers
- Haykin, S. (2011). *Redes Neurais - Principios e práticas* (2nd ed.).
- Jang, J. S. R. (1993). ANFIS: adaptive-network-based fuzzy inference system. *Ieee Transactions On Systems Man And Cybernetics*, 23(3), 665-685. IEEE. doi:10.1109/21.256541
- Kasteren, T. L. M., Englebienne, G., & Kröse, B. J. a. (2010). An activity monitoring system for elderly care using generative and discriminative models. *Personal and Ubiquitous Computing*, 14(6), 489-498.
- Leithardt, V. R. Q., Geyer, C. F. R., Nunes, D., Silva, S. J. ;, Rolim, C. O., Rosseto, A. G. de M., Dantas, M. A. . (2012). Percontrol A Pervasive System for Educational Environments using Wireless Sensor Networks. *International Conference on Computing, Networking and Comm. (ICNC 2012)*.
- Mackey, M. C., & Glass, L. (1977). Oscillation and chaos in physiological control systems. *Science*, 197(4300), 287-289. doi:10.1126/science.267326
- Marza, V., & Teshnehlab, M. (2009). Estimating Development Time and Effort of Software Projects by using a Neuro_Fuzzy Approach. In K. Jayanthakumaran (Ed.), *Advanced Technologies* (pp. 395-412).
- Ramos, C., Augusto, J. C., & Shapiro, D. (2008). Ambient intelligence: The next step for artificial intelligence. *IEEE Intelligent Systems*, 23(2), 15-18.
- Yamin, A. C. (2004). *Arquitetura para um Ambiente de Grade Computacional Direcionada às Aplicações Distribuídas, Móveis e Conscientes de Contexto da Computação Pervasiva*. UFRGS.
- Yau, S. S., Huang, D., Gong, H., & Science, C. (2004). Development and Runtime Support for Situation-Aware Application Software in Ubiquitous Computing Environments. *Computer*.
- Yau, S. S., Wang, Y., Karim, F., & Science, C. (2002). Development of Situation-Aware Application Software for Ubiquitous Computing Environments. *Computer*.
- Ye, J., Dobson, S., & McKeever, S. (2011). A review of situation identification techniques in pervasive computing. *Pervasive and Mobile Computing, In Press*,(0). Elsevier B.V.