

UNIVERSIDADE FEDERAL DE PERNAMBUCO

GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO
CENTRO DE INFORMÁTICA

2014.1

Uma análise das arquiteturas MLP's para previsões das séries temporais

Proposta de Trabalho de Graduação

Aluno: Alvaro Joao Sales Silva Silvino {ajsss@cin.ufpe.br}

Orientador: Germano Crispim Vasconcelos {gcv@cin.ufpe.br}

Recife, 13 de Maio de 2014

Índice

1. Contexto	3
2. Objetivos	4
3. Cronograma	5
4. Referências	6
5. Possíveis Avaliadores	7
6. Assinaturas	8

1. Contexto

Desde o desenvolvimento dos primeiros algoritmos de inteligência artificial e o aprimoramento das redes neurais para a previsão dos elementos a partir de seus dados históricos que as previsões se tornaram elementos chaves para a tomada de decisão [4].

Realizar previsões é uma atividade extremamente importante para o planejamento de qualquer projeto ou realização de alguma atividade. Por tanto, essas técnicas que realizam previsões já são incorporadas nos sistemas que realizam o gerenciamento para o planejamento.

Sendo assim se pode considerar que a previsão de series temporais tem impacto nas seguintes áreas: Planejamento de produção, planejamento financeiro, planejamento de pessoas, planejamento de estoques [4].

Uma rede neural é um sistema de processamento paralelamente distribuído que tem uma unidade simples de processamento, que tem a intensão natural armazenar conhecimento experimental e torna-lo disponível para o uso (Haykin,2001). A inspiração para o funcionamento da rede neural veio dos modelos biológicos do cérebro humano. Onde se assemelha essencialmente em dois aspectos:

- O conhecimento é adquirido a partir de exemplos e treinamentos.
- Pesos nas conexões entre os neurônios, conhecidos como pesos sinápticos, são usados para armazenar o conhecimento.

1.2. Séries temporais

As séries são os dados que se comportam ou que são colhidos com uma frequência característica e contínua seguindo um padrão específico no tempo.

Sendo assim quase todos os que são amostrados ou colhidos sobre alguma frequência no tempo podem ser utilizados. Estão entre esses dados por exemplo: dados de clima, variação na bolsa ou ações, variação de pessoal numa empresa, variação de estoque entre outros [1].

1.3. Perceptron de Múltiplas Camadas (MLP)

Rede neural MLP consiste em diversas camadas, onde existe uma camada entrada, uma ou mais camadas ocultas, e uma camada final chamada de camada de saída, cada camada conectada com a camada sucessora. A arquitetura da rede neural define a quantidade de neurônios nas camadas existentes e também define se existe ou não conexões de realimentação [4].

Assim as arquiteturas disponíveis são as redes recursivas e as redes feedforward ou alimentadas adiante [6].

1.3.1. Feedforward

As redes feedforward são aquelas cuja informação se propaga da camada inicial até a camada de saída sem a retroalimentação de nenhuma camada, isso é as camadas são conectadas com as camadas posteriores [4].

1.3.2. Recursivas

As redes recorrentes diferente das feedforwards possuem conexões de retroalimentação nas camadas. Assim a saída de cada neurônio podem ser alimentada de volta para sua entrada ou para a entrada dos neurônios de suas camadas ou ainda para a camada anterior [4].

2. Objetivos

O objetivo desse estudo é realizar uma comparação dessas duas arquiteturas para o problema de séries temporais. Cada rede tem suas aplicações, vantagens e desvantagens [5]. Para definir essa análise utilizamos as seguintes bases de dados: os índices financeiros da IBOVESP [8], byke sharing de São Francisco e medidas do brilho das estrelas [7].

Para alcançar esse objetivo geral, alguns objetivos secundários foram definidos:

- Estudar arquiteturas MLPs existentes e saber o estado da arte dessa área
- Estuda o problema de séries temporais
- Escolher e aplicar os principais algoritmos de cada arquitetura recursivas e de feedforward nas bases selecionadas
- Fazer uma análise dos resultados da previsão

3. Cronograma

O quadro a seguir representa o cronograma adotado das atividades que serão realizadas durante o trabalho proposto nesse documento:

	Maio			Junho				Julho				Agosto		
Levantamento bibliográfico	■	■	■	■	■									
Análise e desenvolvimento dos algoritmos selecionados			■	■	■	■	■							
Realização dos experimentos								■	■	■				
Análise e consolidação dos resultados obtidos										■	■			
Elaboração do relatório											■	■	■	
Elaboração da apresentação												■	■	■

4. Referências

- [1] George E. P. Box, Gwilym M. Jenkins, and Gregory C. Reinsel. Time Series Analysis: Forecasting and Control. Prentice Hall, New Jersey, third edition, 1994.
- [2] C. T. Chan, C. H. Chuek, D. P. Mital, and T. T. Huat. Time series modelling and forecasting using genetic algorithms. In L. C. Jain, editor, First International Conference on Knowledge-Based Intelligent Electronic Systems, pages 260–268, Adelaide, 1997.
- [3] J. J. Hopfield. Neural networks and physical systems with emergent collective computational abilities. In Proceedings of the National Academy of the Sciences of the U.S.A., volume 79, pages 2554–2558, 1982.
- [4] Tiago A. E. Ferreira, Germano C. Vasconcelos, Paulo J. L. Adeodato. A New Hybrid Approach for Enhanced Time Series Prediction. XXV Congresso da Sociedade Brasileira de Computação, 831–840, 2005.
- [5] Z. Tang, P. A. Fishwick. Feed-forward Neural Nets as Models for Time Series Forecasting. TR91–008 Computer and Information Science Center, University of Florida.
- [6] Aldayr A. Júnior, Adrião D. Neto, Wilson da Mata. PREDIÇÃO NÃO- LINEAR DE CURVAS DE PRODUÇÃO DE PETRÓLEO VIA REDES NEURAIS RECURSIVAS. Volume 97, Tese de Mestrado da UNIVERSIDADE FEDERAL DO RIO GRANDE DO NORTE- UFRN, 2010.
- [7] Machine Learning Repository, Repositório online de base de dados. Disponível em: <<http://archive.ics.uci.edu/ml/>>. Acessado em 13 de Maio de 2014.
- [8] Yahoo Finance, Repositório online de bases financeiras em tempo real, EUA, California 2014. Disponível em : <<http://finance.yahoo.com/>>. Acessado em 13 de Maio de 2014.

5. Possíveis Avaliadores

- Cleber Zanchettin

6. Assinaturas

Trabalho de graduação: Uma análise das arquiteturas MLPs para previsões de séries temporais.

Aluno: Alvaro João Sales Silva Silvino

Orientador: Germano Crispim Vasconcelos

Universidade Federal de Pernambuco

Graduação em Ciência da Computação

Centro de Informática

2014.1

Germano Crispim Vasconcelos
Orientador

Alvaro Joao Silvino
Aluno