

# Fornecer Observações GPS a Modelos Neurais: Uma Tarefa Desafiadora

Prof. Dr.Eng. Carlos Augusto Uchôa da Silva<sup>1</sup>  
Rodrigo Figueiredo Leandro<sup>2</sup>

<sup>1</sup> UFC – Centro de Tecnologia - Depto. de Engenharia de Transportes-DET  
Campus do Pici - Bloco 703 - 60455/760 Fortaleza CE  
uchoa@det.ufc.br

<sup>2</sup> University of New Brunswick - Department of Geodesy and Geomatics Engineering  
P.O. Box 4400, Fredericton, New Brunswick, Canada, E3B 5A3  
rleandro@hotmail.com

**Resumo:** Muito se tem feito em termos de modelagem estocástica e funcional de observações geodésicas, objetivando o desenvolvimento de modelos mais adequados para ajustamento de observações. Uma das técnicas que tem sido foco de mais atenção nos últimos anos é a modelagem através de Redes Neurais Artificiais. Embora, ainda não se use de forma trivial, este tipo de modelagem pode fornecer uma altíssima capacidade de adaptação, que é uma característica de importância fundamental para algumas aplicações. Neste artigo, discute-se o uso de observações GPS em modelos conexionistas, fornecendo-se uma breve descrição dos Modelos baseados em Redes Neurais Artificiais, suas restrições, e principalmente como tratar ou pré-processar observações GPS de modo a satisfazer essas restrições. Uma Rede de Neural é um sistema de processamento de informação formado por um grande número de elementos de processamento simples, chamados de neurônios artificiais. Valores típicos de entrada devem ser normalizados, com amplitude de  $[0,1]$ , ou alternativamente  $[-1,1]$ . Depois de processado, o sinal pode ser convertido de volta a sua escala original. Ao lidar com observações de GPS, isto é, com valores numéricos absolutos normalmente grandes (por exemplo, ordem de 20 milhões de metros para distâncias). Isto, aliado à necessidade de precisões milimétricas para determinação da fase das portadoras e métrica para pseudodistâncias, obriga que as observações GPS sejam modificadas para evitar a degradação de suas precisões durante o processo de normalização, que é necessário à modelagem neural satisfatória de dados de GPS. Neste trabalho são discutidos e apresentados métodos para tornar o uso de dados de GPS possível em modelos neurais a partir de exemplos reais. Realizou-se uma análise tanto para a observável Fase da portadora quanto para a Pseudodistância e demonstra-se que o uso dessas observáveis pode ser feito sem a degradação da precisão desde que seja dado a elas um tratamento matemático adequado.

**Palavras chaves:** GPS, Redes Neurais Artificiais.

**Abstract:** Much has been done in terms of functional and stochastic modelling of observations in space geodesy, aiming at the development of adequate adjustment models. One of the techniques, which has been the focus of more attention in the last years, is the Neural Network model. Although not trivial to be used, this kind of model provides an extreme adaptation capability, which can be an issue of fundamental importance for certain applications. In this paper we discuss the use of GPS observations in Neural Networks models, providing a brief description how a neural model works and what are its restrictions, as well as how to treat the GPS observations in order to satisfy them. A Neural Network is an information processing system formed by a big number of simple processing elements, called artificial neurons. Typically the input values must be normalized, with typical range  $[0,1]$ , or alternatively  $[-1,1]$ . After processed, the signal can be transformed back to its original origin and amplitude. When dealing with GPS observations, namely ranges and range rates, the absolute numerical values are usually pretty large (e.g. order of 20 millions of meters for ranges) coupled with precisions in the order of mm for carrier-phase and meter for pseudoranges. The observations need to be modified to avoid degrading their precision during the normalization, in order to make the application of neural models suitable for GPS data. In this work methods to make the use of GPS data possible in neural models are discussed and showed with real examples. The analysis is made for both pseudoranges and carrier-phases. It is demonstrated that with the adequate treatment the use of those observables can be made without degradation of precision.

**Keywords:** GPS, Neural Networks.

## 1 Introdução

A modelagem tem um papel fundamental na Geodésia. O processamento de sinal, a modelagem funcional de fenômenos físicos, interpolação, previsão e modelagem estocástica são alguns exemplos das aplicações que necessitam de modelagem em Geodésia. Na maioria dos casos são usados ajustamentos, e neste caso, a mais usada é a técnica dos mínimos quadrados. Também usa-se de forma ampla os filtros, como o filtro de Kalman que também envolve alguns conceitos dos mínimos quadrados. No início dos anos noventa uma nova técnica ressurgiu com características úteis para aplicações geodésicas, as chamadas Redes Neurais Artificiais. Apesar de terem sido desenvolvidas principalmente para aplicações computacionais, como reconhecimento de padrões, por exemplo, foram desenvolvidos, posteriormente, modelos baseados em redes neurais para uso em diversos campos de ciência, inclusive Geodésia. Essas adaptações são necessárias em função de que normalmente as situações e problemas encontrados em computação, às vezes são muito diferentes que em outros campos. Geodésia não seria uma exceção, e em função disso, para poder usar esta técnica, o analista de Redes Neurais para Geodésia precisa ter um bom conhecimento em processamento de dados. A adaptação dos dados geodésicos, em alguns casos, pode ser necessária para torná-los passíveis de processamento em um modelo neural.

Este é o caso explorado neste artigo, onde é mostrado o problema de se usar dados GPS com modelagem neural. Compatibilidade entre observações GPS e um modelo neural tem se tornado possível por meio de algumas modificações nos dados GPS originais. Esta inovação sinérgica trouxe consigo a necessidade do desenvolvimento de novas técnicas matemáticas e computacionais de manipulação de dados GPS.

## 2 Modelos Neurais

Uma Rede de Neural é um sistema de processamento de informação formado por um grande número de elementos de processamento simples, chamados de neurônios artificiais, ou simplesmente neurônios. O primeiro modelo de neurônio artificial foi apresentado por Rosenblatt (1958), que recebeu o nome de *perceptron*.




Figura 1 - Modelo de neurônio artificial não linear (Adaptado de Haykin, 1999).

Um perceptron calcula sua entrada como uma combinação linear de seu sinal de entrada usando os pesos de sinápticos. Os pesos sinápticos fazem o papel de parâmetros que são ajustados no processo de treinamento (este procedimento será discutido posteriormente). Os pesos sinápticos armazenam todo conhecimento adquirido pela rede neural. Depois de que uma função de ativação é aplicada à entrada do neurônio para gerar uma saída (no caso de um único neurônio, o sinal o sinal já é a própria saída). Um neurônio pode ter uma ou mais saídas, sempre com o mesmo valor. No caso da função de ativação identidade, o neurônio faz o papel de um modelo linear. O processamento de um neurônio  $k$  pode ser representado por:


$$y_k = \varphi \left( \sum_{i=1}^m (x_i \cdot w_{ki}) + b_k \right), \quad (1)$$

Onde  $y_k$  é a saída do neurônio,  $\varphi$  é a função de ativação,  $m$  é o número de parâmetros de entrada,  $x_i$  é o  $i$ -ésimo parâmetro de entrada,  $w_{ki}$  é o  $i$ -ésimo peso sináptico e  $b_k$  é o bias.

Valores típicos da amplitude normalizada de um neurônio de saída estão dentro do intervalo entre  $[0,1]$ , ou alternativamente  $[-1,1]$ . Este intervalo depende do tipo de função de ativação usado. O modelo de neural inclui também um termo que é aplicado externamente, chamado de *bias* e representado na figura 01 por

$b_k$ . O *bias* tem a função de aumentar ou diminuir a entrada do neurônio.

É possível introduzir uma ligação funcional na rede como uma camada adicional de neurônios, chamada de camada intermediária. Esta camada pode ser composta de um ou mais neurônios. O sinal de entrada dos neurônios da camada intermediária é gerado pelo sinal de saída da camada de entrada. O sinal de saída da camada intermediária é usado para gerar o sinal de entrada à camada de saída. Também é possível introduzir, não apenas uma, mas várias camadas intermediárias no modelo.



**Figura 2 - Rede de Neural Multilayer Perceptron.**


A Figure 2 mostra o esquema de uma rede de neural com uma camada intermediária. Neste exemplo,  $x(1)$ ,  $x(2)$  e  $x(3)$  são os parâmetros de entrada e  $y(t)$  é o parâmetro de saída. Cada elemento, com exceção dos *bias*, é um neurônio. Cada um destes neurônios é um elemento de processamento que trabalha de acordo com equação (1). A união sináptica (as linhas do desenho) conecta camadas diferentes, enquanto transporta o sinal de saída de um neurônio anterior para gerar o sinal de entrada do próximo neurônio. Cada sinapse da rede tem um peso de sináptico correspondente que é aplicado ao sinal corrente que passa por ela.

Outro item de um modelo de rede neural é o número de neurônios de cada camada. Este número é fixado nas camadas de entrada e saída, em função dos parâmetros de entrada e saída. Para as camadas intermediárias este número é arbitrário. O modelo resultante da adição de camadas intermediárias entre as camadas de entrada e saída é chamado de Multilayer Perceptron (MLP), ou Perceptron Multi Camadas. O MLP não é o único tipo de modelo de rede neural, mas é um dos mais populares, devido a sua alta capacidade de adaptação e seu uso em um largo grupo de aplicações diferentes.

Não só é necessário saber qual modelo será usado, bem como todas suas características, como o número de camadas intermediárias, o número de neurônios em cada camada, a função de ativação de cada camada, e outras características mais específicas que não serão abordadas aqui.

Uma vez definido um modelo, é necessário treinar a rede de neural com dados reais. Estes dados constituem um conjunto de entradas e saídas conhecidas. O processo de treinamento não é nada mais que um ajuste dos pesos de sinápticos ao conjunto de dados. Este ajuste tenta diminuir os resíduos da saída da rede. Os resíduos são as diferenças entre a saída calculada pela rede e a saída conhecida. Baseado nestes resíduos executa-se uma atualização dos pesos de sinápticos para o conjunto de dados. Devido à complexidade das redes de neurais, o ajuste não pode ser feito com um cálculo direto, por isso utiliza-se os chamados algoritmos de treinamento, que são um tipo de ajuste iterativo dos pesos sinápticos. Um destes algoritmos é o algoritmo de treinamento *backpropagation*, que é composto através de dois passos. O primeiro é o chamado feed-forward, quando a Rede é alimentada com um jogo de entradas que são propagadas pelas sinapses, da camada de entrada para a camada de saída. Depois, o valor de saída é comparado com a saída conhecida (do mesmo conjunto) e são calculados os resíduos. O segundo passo é o feed-backward. Neste passo a rede é alimentada com os erros do passo anterior que é propagado pela rede da camada de saída para a camada de entrada (para trás). Durante o passo feed-backward, os pesos de sinápticos são ajustados, usando-se para isso as derivadas parciais de cada função de ativação relacionada a cada peso sináptico. Neste passo, um parâmetro adicional também é usado que é a taxa de aprendizagem. A taxa de aprendizagem controla quanto os pesos serão adaptados, determinando a correção da derivada. Estes dois passos são repetidos várias vezes, para todos os

padrões de treinamento, e para várias épocas (uma época é o ciclo onde todos os padrões são uma vez usados no processo de treinamento). É feito várias vezes a cada parâmetro até a convergência dos resíduos a um limiar desejado. Após o processo de treinamento tem-se um Modelo de Rede Neural com os pesos sinápticos ajustados em função dos parâmetros de treinamento. A Figura 3 mostra um gráfico de um processo de treinamento.



**Figura 3 - Processo de treinamento de uma Rede Neural Artificial**

No exemplo acima, a meta do processo de treinamento era alcançar um valor pela somatória dos resíduos quadráticos (ou erros) de 0.001 (a linha direta no gráfico). Este número é dimensionado devido ao processo de normalização pelo qual passaram todos os dados para que se pudesse aplicar a modelagem neural. No caso desta figura, a meta foi alcançada em 222 épocas, quando a rede adquiriu um valor menor que o limiar imposto. Normalmente o valor inicial dos resíduos é alto, porque os pesos da rede têm de ser inicializados de forma arbitrária ou com valores de randômicos.

Redes Neurais Artificiais normalmente podem ser usadas de três modos distintos: como sistemas de simulação de inteligência, como processadores adaptativos em tempo real ou como sistemas de análise de dados. Um das vantagens de modelos de redes de neural é sua alta flexibilidade, permitindo resolver problemas para sistemas dinâmicos e não lineares. A capacidade de generalização permite estimativas de valores nunca usados no processo de treinamento. Neste caso, modelos de neurais podem ser usados com sucesso para aproximação, interpolação, extrapolação, predição temporal. Sua natureza permite o uso de superfícies complexas para representar os fenômenos modelados, sendo que o processo de treinamento torna-se auto-adaptativo. Estas características fazem das redes neurais uma solução atraente, teoricamente Redes Neurais são capazes de modelar qualquer superfície, modelando assim qualquer fenômeno sem um conhecimento aprofundado das relações e correlações entre as variáveis dos fenômenos modelados.

Para conceber com sucesso um modelo de rede neural, são necessários alguns passos. Um dos passos é a definição da topologia ótima da rede, para a aplicação específica a ser usada. A topologia consiste na definição do número de camadas, e o número de neurônios em cada camada. Junto com este passo, há também outros parâmetros a serem estabelecidos, como a taxa de aprendizagem, tipo de funções de ativação e intervalo de normalização. Todos esses desempenham um papel importante no processo de treinamento, e também na capacidade de generalização do modelo de neural. Buscar o conjunto ótimo de parâmetros e topologia mais adequada para uma rede de neural pode ser um trabalho difícil e demorado. Embora alguns autores definam algumas regras para organização de um modelo neural, não há um procedimento definido a seguir para se construir um modelo.

No procedimento de teste (que é executado para testar a eficiência de um modelo candidato para uma determinada aplicação) dependendo da complexidade das topologias, o procedimento de treinamento pode levar muito tempo, até mesmo para computadores rápidos. O tempo de treinamento de uma rede de neural pode variar de alguns segundos a vários dias. Embora seja necessário gastar algum tempo para fixar uma ótima configuração, os resultados das estimativas de rede de neurais normalmente recompensam integralmente o esforço despendido.

### 3 Redes Neurais para Geodésia

Redes Neurais Artificiais se mostraram com uma alternativa atraente em termos de modelagem para várias áreas, e não foi diferente para Geodésia.

Desde o início dos anos noventa vários autores publicaram trabalhos e artigos nos quais relatam o uso de modelos neurais em Geodésia, para aplicações diferentes. Estas aplicações incluem navegação (por exemplo Dumville e Tsakiri (1994), Chansarkar (1999), Vickery e Rei (2002)), aproximação de geóide (por exemplo Kuhar et al (2001)), parâmetros de tempo (atmosfera e espaço) interpolação e previsão (por exemplo Xenos e Stergiou (2002), Silva (2003), Leandro (2004), Leandro e Santos (2004)), predição de parâmetros de orientação de Terra (por exemplo et de Schuh. al. (2002)), designio de redes (por exemplo o Chang et. al. (1996)) e outros.

Normalmente é tentada a utilização de modelos neurais para resolver problemas onde e ferramentas determinísticas de estatística ainda requerem melhorias, ou onde não há um conhecimento muito profundo sobre os fenômenos modelados. Uma aplicação potencial também são os filtros dinâmicos uma vez que a capacidade real de adaptação em tempo real das redes neurais é muito boa. Este é, por exemplo, o caso das aplicações de navegação, quando o modelo de neural tem que “aprender” o padrão do movimento, enquanto fazendo o papel de um filtro preditivo.

Os modelos normalmente desenvolvidos para aproximação e interpolação visam modelar fenômenos para os quais a modelagem com sistemas lineares é complicada, ou as funções determinísticas não se ajustam muito bem na superfície aproximada. Como foi dito anteriormente, uma rede neural pode, teoricamente, aproximar qualquer superfície, dependendo apenas de uma configuração ótima (topologia e outros parâmetros do modelo neural) adaptando-se para cada caso específico. Assim, teoricamente, com a configuração ótima, os modelos neurais são capazes de se ajustar perfeitamente a estes casos. As dificuldades para alcançar isto são: a determinação da configuração ótima, e o tamanho do conjunto de dados disponível treinamento a rede.

Também em termos de previsão, redes neurais têm uma vantagem boa, que lhe é dada por sua capacidade de adaptação. Para o uso de modelos determinísticos é necessário um conhecimento completo do efeito modelado, no caso de redes neurais o modelo pode se adaptar ao comportamento da série temporal para se tornar capaz de prever ocorrências futuras. Mesmo que se considere que uma série tem um componente estocástico, há necessidade de usar um modelo estocástico aliado a um modelo determinístico. No caso de redes neurais não há tal necessidade, porque um único modelo neural pode ser usado para qualquer um ou ambos os componentes. Leandro e Santos (2004) mostraram este tipo de aplicação, enquanto usando redes de neural para prever parâmetros espaço-temporais. Outro exemplo que envolve série temporal é a detecção e correção de perdas de ciclo das portadoras GPS, neste caso podem ser usados onde podem ser usados modelos neurais para predizer os valores das medidas de contagem de ciclos das portadoras GPS.

Longe de ser um concorrente para as técnicas atuais de modelagem, como mínimos quadrados, as redes neurais podem desempenhar um papel importante como uma possibilidade adicional para resolver problemas complexos. Modelos Neurais diferem do ajustamento por mínimos quadrados em vários aspectos, tais como:

- Pesos de Sinápticos em modelos neurais fazem o papel dos parâmetros nos mínimos quadrados;
- A topologia de um modelo neural faz o papel do modelo funcional nos mínimos quadrados;
- Os padrões usados no processo de treinamento podem fazer o papel de junções das observações dentro dos mínimos quadrados, dependendo objetivo do treinamento RMS;
- Os Padrões de teste fazem o papel de pontos de controle;
- Os Erros no processamento neural são semelhantes aos resíduos das observações em ajustamento por mínimos quadrados;
- O processo de treinamento faz o papel do ajustamento de parâmetros;
- A taxa de aprendizagem faz o papel de um peso de observação (controla a atualização dos pesos sinápticos);
- Uma época em redes neurais no processo de treinamento faz o papel de uma repetição em um ajustamento;
- No método dos mínimos quadrados, o modelo funcional tem que ser construído para representar os fenômenos. Em redes neurais, a topologia é construída para ser capaz de se adaptar aos fenômenos analisados

Existem várias diferenças entre as duas técnicas, em alguns casos redes neurais e mínimos quadrados podem trabalhar juntos. Este é o caso de usar modelagem neural como a parte da transição do Filtro de Kalman. Por exemplo, pode-se tirar proveito de modelo funcional bem conhecido para posicionamento para construir o ajuste de atualização de um filtro de navegação, junto com uma rede neural que faz o papel de um estimador de navegação como a transição.

Redes Neurais, quando usadas corretamente são uma ferramenta muito eficaz que pode fazer diferença quando comparada às técnicas atuais função de uma altíssima capacidade de adaptação. Suas aplicações potenciais são incontáveis, estando restrita apenas pela imaginação do geodesta, quando pensar em unir um modelo neural a um problema de Geodésia.

#### 4 Alimentando Modelos Neurais com Observações GPS

Quando se aventa a possibilidade do uso dados GPS em modelos neurais como um assunto relevante, a primeira questão que se coloca é: porque se deve dar um tratamento especial a esses dados antes de utilizá-los? De fato, há algumas razões para isso e a primeira, talvez a mais importante seja a necessidade que o processamento neural tem de usar valores de entrada e saída compreendidos no intervalo entre 0 e 1 (zero e um), ou entre -1 e 1 (menos um e um). Isto significa que valores com ordem de grandeza de dezenas de milhares de quilômetros (como no caso de pseudodistâncias) ou até centenas de milhares de ciclos (no caso da fase das portadoras) devem ser reduzidos a intervalos pequenos, além disso, o modelo precisa ainda ser capaz de fornecer estimativas com precisão compatível aos dados originais. Um outro aspecto a ser considerado é a compatibilidade entre padrões de treinamento de diferentes observações e os padrões de teste. A capacidade da generalização do modelo depende desta coerência ao se transformar série de dados originais.

O valor mais usado em redes neurais para a análise de desempenho é o MSE (erro médio quadrático). O MSE pode ser calculado com a seguinte equação:

$$MSE = \frac{1}{np} \sum_{i=1}^{np} e^2 \quad (2)$$

Onde  $np$  representa o número de padrões usados durante o processo de treinamento. É fácil perceber que o MSE não é nada mais do que a variância das estimativas da rede neural. Conseqüentemente, com este valor pode-se relacionar o desempenho da rede com variâncias estimadas para dados reais. Entretanto, como os dados manipulados para modelos neurais são normalizados, faz-se necessário uma transformação, que pode facilmente ser derivada da lei da propagação de erros:

$$\sigma^2 = NF^2 \cdot MSE \quad (3)$$

Onde  $\sigma^2$  é a variância estimada e  $NF$  é o fator de normalização. Como pode-se perceber a partir das equações 2 e 3, pode-se dizer que a variância das estimativas de uma rede neural é função do MSE (neste caso, do desempenho da rede) e do fator de normalização usado para ajustar o conjunto de dados ao processamento. Conseqüentemente, o valor do fator de normalização desempenha um papel fundamental na variância das estimativas, quando as estimativas forem transformadas de volta do domínio normalizado aos seus valores reais.

Nos exemplos utilizados neste trabalho, projetou-se um modelo neural para estimar observações de ciclos da portadora L2 (pseudodistância e fase da portadora), fornecendo-se as observações da portadora L1. O processo de treinamento foi realizado com os dados de uma rede do GPS, e a simulação (com a rede neural já treinada para poder estimar a observável L2) realizada para um determinado receptor. A Figura 4 mostra o esquema do processamento dos dados.

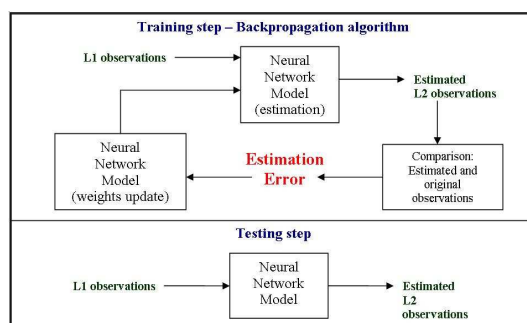



Figura 4 - Esquema do processo de dados


Neste caso o primeiro obstáculo foi fazer com as medidas da contagem de ciclos da fase das portadoras se ajustassem em um intervalo normalizado. A primeira decisão tomada ajustar o intervalo normalizado no intervalo entre -1 e 1, que fornece um fator de normalização duas vezes menor que o intervalo entre 0 e 1.

A Figura 5 mostra um exemplo de medidas de fase das portadoras para L1 e L2.



**Figura 5 - Medidas da fase do portador (L1 e L2).**

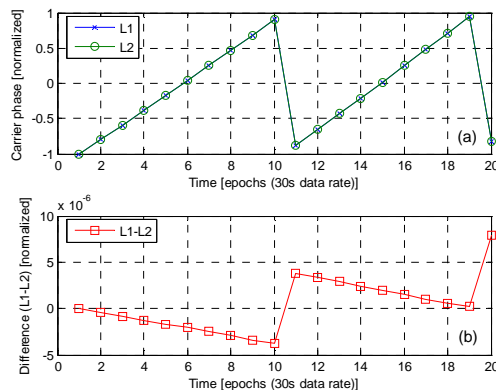
Como se pode ver na Figura 5, há uma diferença da referência entre as duas frequências, dada por números diferentes atribuídos à ambigüidade inicial do ciclo, e também uma diferença na taxa, dada por comprimentos de onda diferentes. Devido a estas diferenças, foi difícil relacionar L1 e L2, como se desejava. Este é um problema típico de coerência entre os padrões gerados por observáveis diferentes. Como o valor inicial do contador de fase é arbitrário, trabalhar com estas diferenças pode conduzir a elevados fatores de normalização. Uma segunda implicação é que cada par receptor-satélite tem um valor diferente para estas diferenças. Para resolver este problema usou-se o metro (m) como a unidade comum para ambas as frequências. Os contadores também foram sincronizados, atribuindo-se a mesma contagem inicial para ambas as portadoras (neste caso zero) como é mostrado em figura 6.



**Figura 6 - (a) Medidas de fase das portadoras (L1 e L2) após a sincronização e (b) Conversão das unidades para metros.**

Após as modificações relatadas acima, o problema de relacionamento entre as duas frequências foi resolvido. Contudo, os valores para os fatores de normalização seriam ainda elevados ainda, por causa da larga escala de valores para fase das portadoras, neste caso pensou-se na utilização de algumas técnicas.

A primeira a ser mencionada é adicionar falsas perdas de ciclo na contagem de fase das portadoras. Esta técnica apresentada inicialmente por Silva (2003) consiste em adicionar falsas perdas de ciclo na contagem de fase das observações, ajustar o valor máximo do contador, a fim manter o fator de normalização dentro de um dado valor. O resultado de aplicar essas falsas perdas de ciclos nas medidas de fase da portadora é mostrado na Figura 7.




**Figura 7 - (a) Medidas da fase da portadora (L1 e L2) com falsas perdas de ciclos e (b) a diferença entre L1 e L2 normalizados.**

A desvantagem de usar esta técnica vem das próprias perdas de ciclo. Para uma série de tempo longa, tem de se lançar mão de diversas, e para cada série subsequente entre perdas de ciclos, os erros das estimativas se acumulam quando se tem a série sem perdas de ciclos. A Figura 7b mostra como são pequenas as diferenças entre L1 e L2 quando os dados são normalizados. O modelo neural deve ser sensível a estas variações. Implicitamente, minimizando o fator de normalização estas pequenas

diferenças são detectadas mais facilmente quando são processadas em uma rede neural.

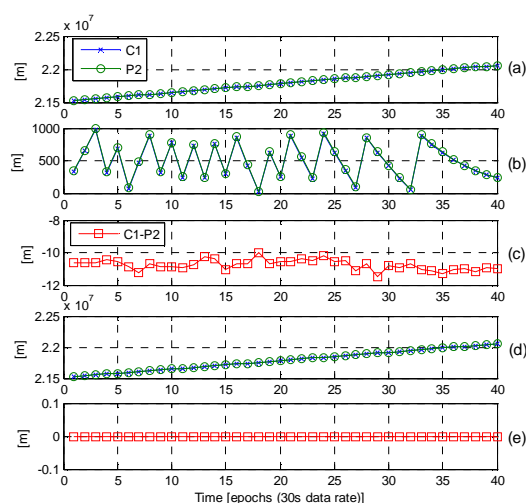
Uma outra técnica que pode ser usada é diferença de tempo das observações. Esta aproximação reduz a escala em que os contadores da fase variam. Entretanto, similarmente a técnica descrita anteriormente, os erros na predição começam acumulados no tempo ao se reconstruir uma série temporal sem perdas de ciclo. Este efeito deve ser compensado pelo valor muito menor do fator de normalização. Dependendo do tipo de potencialidade da série e da capacidade de generalização da rede neural, essa pode ser uma boa opção. Porém, geralmente o modelo não tem um desempenho muito bom quando se tem séries temporais longas. A Figura 8 mostra um exemplo de aplicação desta técnica.



**Figura 8 – Diferenças de fase da portadora.**

Pode-se observar que a escala dos valores é muito menor do que a mostrada na figura 6b, por exemplo. Comparando os dois casos, o fator de normalização seria aproximadamente 500 vezes menor para este caso. Por exemplo, supondo o mesmo MSE, a variância das estimativas seria muito menor nesta última situação. Esta técnica foi usada para a análise mencionada no começo desta seção. Demonstrou-se a obtenção de melhores resultados em termos de estimativas de fase da portadora.

Uma outra técnica que possa ser usada é o procedimento inverso de truncamento. Consiste em truncar o número em um tamanho máximo de números significativos. É chamado inverso, porque nesta técnica em vez de guardar o lado esquerdo do número, guarda-se o lado do direito. É uma técnica muito útil quando se deseja relacionar duas quantidades muito similares, não dependendo de seus valores absolutos, mas somente até um determinado nível. Por exemplo, deseja-se relacionar pseudodistâncias medidas a partir do código CA e P. Como se sabe que a diferença entre essas duas grandezas está abaixo de 100m, pode-se manter os números inalterados até centenas e supor que o resto dos valores (lado esquerdo) deve ser sempre o mesmo. Naturalmente este procedimento também contribui fortemente para a diminuição dos fatores de normalização. A Figura 9 mostra os resultados desta técnica, aplicada a pseudodistâncias. A figura 9a mostra as pseudodistâncias (CA e P2) com seus valores originais. A figura 9b mostra os valores após a aplicação da técnica do truncamento inverso. A escala dos valores decai da ordem de  $10^7$  à ordem de  $10^3$ . A Figura 9c mostra a diferença dos valores C1 e P2 (após o truncamento). Na figura 9d o resto (parte esquerda do número) das pseudodistâncias (eliminados na modificação) é mostrada e Figura 9e mostra a diferença entre estes valores (CA - P2). Pode-se observar da figura 9e que a parte eliminada dos números é sempre exatamente a mesma para ambas as observáveis, isto mantém a suposição de coerência entre os padrões gerados pela diferentes observáveis.



**Figura 9 - Técnica do truncamento inverso.**

Outras técnicas, além das mostradas neste trabalho também podem ser usadas. Um exemplo disto é a redução funcional usada por Leandro et. al. (2005) para modificar uma série temporal de pseudodistâncias a fim alimentar modelos estocásticos. Esta redução consiste remover a distância matemática e outros efeitos sistemáticos das observações. Em termos de processamento neural esta aproximação pode ser bastante útil, todavia em alguns casos poder trazer algumas dificuldades. Por exemplo, devido a coerência entre padrões, as coordenadas de receptores diferentes devem ser bem conhecidas. Caso um ou os mais receptores tiverem suas posições desconhecidas esta técnica poderia introduzir polarizações na série reduzida, o que pode complicar o processo do treinamento. Esta é a razão pela qual esta técnica não foi usada neste caso específico. Entretanto, pode ser útil em outras situações, como em aplicações que tratam de apenas um receptor.

No processamento de dados onde todas essas técnicas foram aplicadas, os melhores resultados foram obtidos quando a técnica diferenças entre épocas consecutivas da fase da portadora foi usada para as fases das portadoras e o truncamento inverso foi usado para pseudodistâncias. Embora estas técnicas apresentassem melhores resultados nestes casos, isso não significa que são melhores do que outros, mas simplesmente que eram mais apropriadas para a situação específica. Em outros casos, as outras técnicas mostradas poderão ser mais adequadas.

## 5 conclusões

Os modelos de Redes Neurais necessitam de dados compreendidos em intervalos normalizados, o que requer a modificação na série de dados originais. Pode-se utilizar diversas técnicas par modificação dos dados a fim de adaptá-los ao uso em modelos neurais. Neste artigo mostrou-se algumas das técnicas que podem ser úteis para uso de observações Geodésicas em modelos neurais, bem como suas vantagens e desvantagens.

Definitivamente a escolha do procedimento mais adequado no pré-processamento dos dados para uso em modelos neurais pode produzir grandes variações na qualidade das estimativas quando convertidas a sua escala original (desnormalizados).

As técnicas mostradas neste trabalho não pretendem esgotar o assunto, nem mesmo se arvorarem como sendo todas as alternativas existentes e outras diferentes das apresentadas aqui, certamente podem existir algumas mais uniformes e com outras abordagens. A variedade de soluções para este tipo do problema pode ser tão grande quanto à possibilidade de emprego de modelos neurais. Mas, uma contribuição relevante deste trabalho é a de mostrar a importância de determinados problemas e dificuldades no trato de dados geodésicos (tais como o GPS), bem como a apresentação de algumas soluções úteis. Se não forem aplicáveis para um caso específico, pode-se, pelo menos, usar parte dos conceitos explorados aqui como auxílio na busca de adaptações necessárias a cada uso.

É impossível apontar qual das técnicas ou artifícios mostrados é melhor, porque em cada caso uma solução diferente pode ser a ótima. Como foi o caso mostrado neste trabalho, onde a técnica usada para tratar pseudodistâncias foi diferente da usada para tratar a fase da portadora.

Embora os dados usados neste trabalho fossem medidas GPS, os procedimentos apresentados aqui, podem ser potencialmente aplicados a qualquer tipo de medida com características similares.

## 6 Referências Bibliográficas.

- Chang, Y. M.; Chen, C. H.; Chen, C. S.** (1996). Optimal Observation Design of Surveying Network using Artificial Neural Network. Geomatics Research Australasia, No.64, June, 1996, pp. 1-16.
- Chansarkar, M.** (1999). GPS Navigation using Neural Networks. 12th International Technical Meeting of the Satellite Division of the Institute of Navigation, September 14-17, 1999, Nashville Convention Center, Nashville, Tennessee.
- Dumville, M. and Tsakiri, M.** (1994). An Adaptive Filter for Land Navigation Using Neural Computing. 7th International Technical Meeting of The Satellite Division of The Institute of Navigation, September 20-23, 1994, Salt Palace Convention Center - Salt Lake City, UT.
- Haykin, S.** (1999). Neural Networks – A Comprehensive Foundation. Prentice Hall – Upper Saddle River, New Jersey.

- Kuhar, M.; Stopar, B.; Turk, G.; Ambrozic, T.** (2001). The use of artificial neural network in geoid surface approximation. *Allgemeine Vermessungs-Nachrichten*, Vol.108, No.1, 2001, pp. 22-27.
- Leandro, R. F.** (2004). A New Technique to TEC Regional Modeling using a Neural Network. ION GNSS 2004, September, 2004, Long Beach, California.
- Leandro, R. F. and Santos, M. C.** (2004). Comparison between autoregressive model and neural network for forecasting space environment parameters. *Bollettino di Geodesia e Scienze Affini*, Vol.63, No.3, 2004, pp. 197-212.
- Maia, T.C.B., Silva C.A.U., Leandro R.F., Segantine P.C.L., Romero R.A.F.** (2002). Predição da Contagem de Ciclos da Portadora GPS Utilizando uma Modelagem Conexionista Temporal – FIR MLP. XVI Brazilian Symposium on Neural Networks. Porto de Galinhas, Recife, Brazil.
- Schuh, H.; Ulrich, M.; Egger, D.; Mueller, J.; Schwegmann, W.** (2002). Prediction of Earth orientation parameters by artificial neural networks. *Journal of Geodesy*, Vol.76, No.5, 2002, pp. 247-258.
- Silva, C. A. U.** (2003). Um Método para estimar Observáveis GPS a partir de Redes Neurais Artificiais. Tese Escola de Engenharia de São Carlos - Universidade de São Paulo, 113p.
- Vickery, J. L. and King, L. R.** (2002). Use of Neural Networks and Expert Systems for Rapid Differential GPS Navigation. ION GPS 2002, September 24-27, 2002, Oregon Convention Center, Portland, Oregon.
- Xenos, T. D. and Stergiou, D. C.** (2002). One day before foF2 neural network based prediction models: A performance comparison between ordinary, fuzzy and recurrent neural networks. *Acta Geodaetica et Geophysica Hungarica*, Vol.37, No.2-3, 2002, pp. 293-296.