UNIVERSIDADE DE SÃO PAULO
ESCOLA DE ENGENHARIA DE SÃO CARLOS
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA DE TRANSPORTES

CASSIO VINÍCIUS CARLETTI NEGRI

**Estimativa das observáveis GPS da portadora L2 por meio de Redes
Neurais Artificiais a partir de dados obtidos em dispositivos móveis**

SÃO CARLOS

2018

CASSIO VINÍCIUS CARLETTI NEGRI

**Estimativa das observáveis GPS da portadora L2 por meio de Redes
Neurais Artificiais a partir de dados obtidos em dispositivos móveis**

**Programa de Pós-graduação em
Engenharia de Transportes da EESC-USP**

**Exemplar definitivo (corrigido). O exemplar
original está disponível na CPG da EESC-USP**

São Carlos, 07/01/2019

RESOLUÇÃO CoPGr N ° 6018, DE 13 DE OUTUBRO DE 2011, artigo 5ª

Dissertação apresentada ao Programa de Pós-graduação em Engenharia de Transportes, da Escola de Engenharia de São Carlos (EESC), da Universidade de São Paulo (USP), como parte dos requisitos para obtenção do título de Mestre em Ciências.

Área de concentração: Infraestrutura de Transportes (Geomática).

Orientador: Prof. Associado Paulo Cesar Lima Segantine.

SÃO CARLOS

2018

AUTORIZO A REPRODUÇÃO TOTAL OU PARCIAL DESTE TRABALHO,
POR QUALQUER MEIO CONVENCIONAL OU ELETRÔNICO, PARA FINS
DE ESTUDO E PESQUISA, DESDE QUE CITADA A FONTE.

Ficha catalográfica elaborada pela Biblioteca Prof. Dr. Sérgio Rodrigues Fontes da
EESC/USP com os dados inseridos pelo(a) autor(a).

N386e Negri, Cassio Vinícius Carletti
 Estimativa das observáveis GPS da portadora L2 por
 meio de Redes Neurais Artificiais a partir de dados
 obtidos em dispositivos móveis / Cassio Vinícius
 Carletti Negri; orientador Paulo Cesar Lima Segantine.
 São Carlos, 2018.

 Dissertação (Mestrado) - Programa de Pós-Graduação
 em Engenharia de Transportes e Área de Concentração em
 Infraestrutura de Transportes -- Escola de Engenharia
 de São Carlos da Universidade de São Paulo, 2018.

 1. GPS. 2. GNSS. 3. Posicionamento de pontos. 4.
 RNA. 5. Geração das observáveis L2. 6. Smartphones. 7.
 Dispositivos Android. 8. Receptores de baixo custo. I.
 Título.

Eduardo Graziosi Silva - CRB - 8/8907

FOLHA DE JULGAMENTO

Candidato: Engenheiro **CASSIO VINÍCIUS CARLETTI NEGRI.**

Título da dissertação: " Estimativa das observáveis GPS da portadora L2 por meio de Redes Neurais Artificiais a partir de dados obtidos em dispositivos móveis ".

Data da defesa: 19/12/2018

Comissão Julgadora:

Resultado:

Prof. Associado **Paulo Cesar Lima Segantine**
(Orientador)
(Escola de Engenharia de São Carlos/EESC-USP)

Aprovado

Profa. Titular **Roseli Aparecida Francelin Romero**
(Instituto de Ciências Matemáticas e de Computação/ICMC-USP)

APROVADO

Prof. Dr. **Duglas Barreto**
(Universidade Federal de São Carlos/UFSCar)

APROVADO

Coordenadora do Programa de Pós-Graduação em Engenharia de Transportes:

Profa. Associada **Ana Paula Camargo Larocca**

Presidente da Comissão de Pós-Graduação:
Prof. Titular **Luís Fernando Costa Alberto**

*Dedico este trabalho a Deus e aos
meus familiares, em especial aos
meus pais, Rita e Paulo.*

AGRADECIMENTOS

Primeiramente a Deus, que ilumina a minha jornada e oferece a cada desafio a chance de nos tornarmos cada vez melhores.

À minha família, alicerce sólido sobre o qual minha vida é construída, em especial aos meus pais Paulo e Rita, meus avós Creuza, José, Cecília e Júlio (*in memoriam*) que, cada um a seu próprio modo, contribuíram para que eu me tornasse a pessoa que sou.

Ao querido orientador e professor Paulo Cesar Lima Segantine pelo apoio, orientação, respeito, amizade, confiança para a realização do trabalho e estímulo para a vida acadêmica.

À minha namorada Maria Eduarda, pelo apoio nos momentos difíceis, pela força quando esmoreci, pelo amor e o companheirismo a toda prova.

À Escola de Engenharia de São Carlos por todos os recursos e infraestrutura disponibilizados para a realização do Mestrado.

Aos professores e funcionários do Departamento de Engenharia de Transportes e à professora Roseli Aparecida Francelin Romero, do Instituto de Ciências Matemáticas e de Computação (ICMC), por toda a ajuda e ensinamentos.

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) pela concessão da bolsa de estudo, sendo o presente trabalho realizado com o seu apoio - Código de Financiamento 001.

Ao grupo de pesquisa da área de Geomática, do Departamento de Engenharia de Transportes, em especial aos amigos Francisco Roza de Moraes e Andre Borgato Morelli, os quais colaboraram de forma muito significativa com o desenvolvimento do software RINEX ADAPTER 2018 e com a implementação das Redes Neurais Artificiais (RNAs) na biblioteca TensorFlow, pela linguagem Python.

Aos colegas e a todos que de maneira direta ou indireta contribuíram para a conclusão desta etapa.

*“O impossível não é um fato: é uma
opinião.” (CORTELLA, 2018).*

RESUMO

NEGRI, C. V. C. **Estimativa das observáveis GPS da portadora L2 por meio de Redes Neurais Artificiais a partir de dados obtidos em dispositivos móveis**. 2018. 151 p. Dissertação (Mestrado em Engenharia de Transportes). Escola de Engenharia de São Carlos (EESC), Universidade de São Paulo (USP). São Carlos, 2018.

Ao longo dos anos, o posicionamento por satélites artificiais através da geotecnologia *Global Navigation Satellite System* (GNSS) e, principalmente, por meio do sistema americano *Global Positioning System* (GPS), ganhou importante espaço na área de Geomática. A qualidade das soluções está diretamente relacionada, entre outros fatores, ao tipo de receptor utilizado no trabalho: dispositivos mais caros (geodésicos), capazes de gerar as portadoras L1 e L2 ou L1, L2 e L5, produzem os melhores resultados; por outro lado, receptores topográficos que rastreiam apenas a frequência L1 são mais baratos, mas tornam o processamento dos dados dependente de um modelo ionosférico para reduzir parcialmente os efeitos dessa origem. Visando melhorar as soluções de posicionamento com dispositivos de baixo custo e evitar despesas adicionais do usuário que, eventualmente, necessitaria de utilizar aparelhos mais onerosos, este trabalho tem como objetivo principal propor a implementação de uma Rede Neural Artificial (RNA) para estimar as observações da portadora L2 do sistema GPS com base nas observáveis da L1, buscando-se também aprimorar o método de predição destes dados elaborado em outras pesquisas. Para tanto, selecionou-se um modelo de rede através da técnica de Validação Cruzada (CV), estimaram-se as observações a partir das rastreadas tanto em um receptor geodésico como em um smartphone Android, e comparou-se a acurácia das soluções que foram processadas com e sem as observáveis artificiais criadas pela RNA. A técnica CV demonstrou que uma *Multilayer Perceptron* (MLP) de quatro camadas escondidas e outra de uma camada intermediária são as configurações mais apropriadas para estimação das observáveis do código e da fase da portadora L2, respectivamente. O tempo de aprendizagem em todos os experimentos não ultrapassou poucos segundos e o processamento dos arquivos RINEX de dupla frequência, criados neste trabalho, revelou melhorias significativas das soluções de posicionamento na maioria dos testes, reduzindo os desvios planos e espaciais em torno de 40 a 50% em relação aos resultados atingidos com apenas os dados originais da portadora L1, sendo que em alguns experimentos foi possível realizar a combinação *iono-free* (L3) e em outros atender a normativa de georreferenciamento de imóveis rurais do Instituto Nacional de Colonização e Reforma Agrária (INCRA). Os resultados apontam, portanto, que a proposta metodológica da presente investigação atua de forma bastante promissora e como uma alternativa ao uso de receptores mais caros.

Palavras-chave: GPS. GNSS. Posicionamento de pontos. RNA. Geração das observáveis L2. Smartphones. Dispositivos Android. Receptores de baixo custo.

ABSTRACT

NEGRI, C. V. C. **Estimation of the GPS L2 observables by use of Artificial Neural Networks from data obtained in mobile devices**. 2018. 151 p. Dissertation (M. Sc. in Transportation Engineering). São Carlos School of Engineering (EESC), University of São Paulo (USP). São Carlos, 2018.

Over the years, positioning by artificial satellites through the Global Navigation Satellite System (GNSS) and, mainly, through the American Global Positioning System (GPS), has become increasingly important in Geomatics. The quality of the solutions is directly related, among other factors, to the receiver type used in the work: more expensive (geodetic) devices, capable of generating the carriers L1 and L2 or L1, L2 and L5, produce the best results; conversely, topographic receivers which only trace the L1 frequency are cheaper, but make data processing dependent on an ionospheric model to partially reduce the effects of that source. In order to improve the positioning solutions with low cost devices and avoid additional financial costs to the user who would ultimately need to use more expensive devices, the main objective of this work is to propose the implementation of an Artificial Neural Network (ANN) to estimate the GPS L2 observations from the L1 observables, aiming also to improve the prediction method elaborated in other research. This was done by using the Cross-Validation (CV) technique to select a network model. The observations were estimated from observables tracked on both a geodetic receiver and an Android smartphone, and we compared the accuracy of the solutions that were processed with and without the artificial observations created by the ANN. The CV technique demonstrated that a Multilayer Perceptron (MLP) of four hidden layers and another of an intermediate layer are the most appropriate configurations for the estimation of the L2 code and phase observables, respectively. The learning time in all the tests did not exceed a few seconds and the processing of the dual frequency RINEX files, which were created in this work, revealed significant improvements in the positioning solutions in all the experiments. The plane and spatial deviations were reduced by around 40% to 50% in relation to the results obtained with only the original L1 carrier data. In some tests it was possible to perform the iono-free combination (L3) and in others to meet the georeferencing regulations for rural properties of the National Institute of Colonization and Agrarian Reform (INCRA). The results indicate, therefore, that the methodological proposal of the present investigation acts in a very promising way and as an alternative to the use of more expensive receivers.

Key-words: GPS. GNSS. Point positioning. ANN. Generation of the L2 observables. Smartphones. Android devices. Low-cost receivers.

LISTA DE FIGURAS

Figura 1 - Representação genérica da estrutura dos sinais GPS.....	38
Figura 2 - Fac-símile de um arquivo RINEX de observação (estação RBMC-EESC do dia 25/09/2018).....	42
Figura 3 - Esquema da DD de fases entre dois satélites e duas estações	44
Figura 4 - Vetor (linha base) entre duas estações	48
Figura 5 - Célula piramidal, ou neurônio piramidal	52
Figura 6 - Modelo não linear de um neurônio artificial k	54
Figura 7 - Rede <i>Feedforward</i> de Camadas Múltiplas.....	58
Figura 8 - a) Representação da época de parada do treinamento de acordo com o menor valor de MSE de validação; b) Esquema genérico de mínimos locais e global em função da inicialização dos pesos sinápticos (W) de um modelo	62
Figura 9 - Disposição das estações RBMC utilizadas	67
Figura 10 - Disposição do smartphone Galaxy S8 sobre o marco de concreto	72
Figura 11 - Tela principal do aplicativo Geo++ RINEX Logger para Android	72
Figura 12 - Tela inicial do programa RINEX ADAPTER 2018	73
Figura 13 - Fluxograma das etapas do método proposto.....	74
Figura 14 - Comparação entre os modelos com diferentes quantidades de camadas escondidas e neurônios artificiais - Dia 20/01/2016 (15:00 – 15:30 h)	77
Figura 15 - Comparação entre as funções de ativação - Dia 10/01/2015 (14:30 – 15:00 h)	78
Figura 16 - Comparação entre os algoritmos de otimização - Dia 15/09/2014 (13:00 – 13:30 h)	79
Figura 17 - Comparação entre os métodos de inicialização de pesos sinápticos - Dia 10/06/2015 (13:00 – 13:30 h)	79
Figura 18 - Comparação entre os modelos com diferentes quantidades de camadas escondidas e neurônios artificiais - Dia 20/01/2016 (15:00 – 15:30 h)	81
Figura 19 - Comparação entre as funções de ativação - Dia 15/09/2014 (13:00 – 13:30 h)	82
Figura 20 - Comparação entre os algoritmos de otimização - Dia 10/06/2015 (13:30 – 14:00 h)	83
Figura 21 - Comparação entre os métodos de inicialização de pesos sinápticos - Dia 10/01/2015 (14:30 – 15:00 h)	84
Figura 22 - Desvios planos do processamento relativo para o dia 15/09/2014 (Teste 1).....	88
Figura 23 - Desvios espaciais do processamento relativo para o dia 15/09/2014 (Teste 1).....	89

Figura 24 - Desvios planos do processamento relativo para o dia 10/01/2015 (Teste 2)	89
Figura 25 - Desvios espaciais do processamento relativo para o dia 10/01/2015 (Teste 2)	90
Figura 26 - Desvios planos do processamento relativo para o dia 10/06/2015 (Teste 3)	90
Figura 27 - Desvios espaciais do processamento relativo para o dia 10/06/2015 (Teste 3)	91
Figura 28 - Desvios planos do processamento relativo para o dia 20/01/2016 (Teste 4)	91
Figura 29 - Desvios espaciais do processamento relativo para o dia 20/01/2016 (Teste 4)	92
Figura 30 - Box Plot das coordenadas verticais	93
Figura 31 - Comparação dos desvios espaciais para diferentes quantidades de épocas de treinamento da RNA da fase da portadora – Dia 15/09/2014	94
Figura 32 - Desvios planos do processamento PPP para os quatro experimentos da segunda parte da metodologia (5, 6, 7 e 8)	96
Figura 33 - Desvios espaciais do processamento PPP para os quatro experimentos da segunda parte da metodologia (5, 6, 7 e 8)	96

LISTA DE TABELAS

Tabela 1 - Bandas de frequência do sinal GPS.....	38
Tabela 2 - Fontes de erros no posicionamento com o sistema GPS	45
Tabela 3 - Data e horário dos testes com as estações RBMC.....	68
Tabela 4 - Coordenadas oficiais da estação RBMC de São Carlos (EESC).....	69
Tabela 5 - Coordenadas oficiais dos marcos SAT 93509 e 93670.....	70
Tabela 6 - Data e horário dos testes com o smartphone	71
Tabela 7 - MSE dos subconjuntos de validação e tempo de treinamento das RNAs do código	85
Tabela 8 - MSE dos subconjuntos de validação e tempo de treinamento das RNAs da fase...	86
Tabela 9 - Somatória total do número de épocas de treinamento e tempo para geração das observáveis da portadora L2.....	87
Tabela 10 - Comparação dos valores de MSE de validação e tempo de treinamento da RNA da fase da portadora para diferentes quantidades de iterações – Dia 15/09/2014.....	94

LISTA DE ABREVIATURAS

ABNT	Associação Brasileira de Normas Técnicas
AI	<i>Artificial Intelligence</i>
ASCII	<i>American Standard Code for Information Interchange</i>
C/A	Coarse Acquisition
CAPES	Coordenação de Aperfeiçoamento de Pessoal de Nível Superior
CV	Validação Cruzada
DD	Dupla Diferença
DGPS	<i>Differential Global Positioning System</i>
DoD	Departamento de Defesa dos Estados Unidos da América
EESC	Escola de Engenharia de São Carlos
EUA	Estados Unidos da América
foF2	Frequência crítica da camada F2 da ionosfera
GDOP	<i>Geometric Dilution of Precision</i>
GIS	<i>Geographic Information Systems</i>
GNSS	<i>Global Navigation Satellite System</i>
GPS	<i>Global Positioning System</i>
IBGE	Instituto Brasileiro de Geografia e Estatística
ICMC	Instituto de Ciências Matemáticas e de Computação
INCRA	Instituto Nacional de Colonização e Reforma Agrária
INS	<i>Inertial Navigation System</i>
IRI	<i>International Reference Ionosphere</i>
MIT	<i>Massachusetts Institute of Technology</i>
MLP	<i>Multilayer Perceptron</i>
MSE	<i>Mean Squared Error</i>
OCXO	<i>Oven-Controlled Crystal Oscillator</i>
PPP	<i>Precise Point Positioning</i>
RBMC	Rede Brasileira de Monitoramento Contínuo dos Sistemas GNSS
ReLU	<i>Rectified Linear Unit</i>
RINEX	<i>Receiver Independent Exchange Format</i>
RNA	Rede Neural Artificial

RWNN	<i>Recurrent Wavelet Neural Network</i>
SD	Simple Diferença
SGD	Gradiente Descendente
SIG	Sistema de Informações Geográficas
SIRGAS	Sistema de Referência Geocêntrico para as Américas
SNR	<i>Signal-To-Noise Ratio</i>
STT	Departamento de Engenharia de Transportes
TCXO	<i>Temperature-Compensated Crystal Oscillator</i>
TD	Tripla Diferença
TEC	Conteúdo Total de Elétrons
USP	Universidade de São Paulo
WNN	<i>Wavelet Neural Network</i>

SUMÁRIO

1 INTRODUÇÃO	23
1.1 JUSTIFICATIVA	24
1.2 ESTRUTURA DA DISSERTAÇÃO	26
2 REVISÃO BIBLIOGRÁFICA	27
3 SISTEMA GLOBAL DE POSICIONAMENTO (GPS)	37
3.1 O SINAL GPS	37
3.2 OBSERVÁVEIS GPS	39
3.2.1 O formato RINEX	41
3.2.2 Diferença de fases.....	43
3.3 ORIGEM DOS ERROS NO POSICIONAMENTO COM O SISTEMA GPS	44
3.4 RECEPTORES GNSS	46
3.5 MÉTODOS DE POSICIONAMENTO DE PONTOS	47
3.5.1 Processamento pelo método relativo estático	48
3.5.2 Processamento pelo método PPP	49
4 REDES NEURAIS ARTIFICIAIS.....	51
4.1 INSPIRAÇÃO BIOLÓGICA	51
4.2 REDES NEURAIS ARTIFICIAIS E O NEURÔNIO ARTIFICIAL	53
4.2.1 Propriedades e Benefícios	54
4.3 DEFINIÇÃO E CONCEITOS GERAIS	55
4.3.1 Funções de Ativação.....	55
4.3.2 Arquitetura de uma Rede Neural Artificial	56
4.3.3 Processo de Aprendizagem.....	59
4.4 <i>MULTILAYER PERCEPTRON</i> (MLP) – REDE PERCEPTRON DE MULTICAMADAS (PMC)	60
4.4.1 Medida de desempenho e obtenção do melhor modelo.....	61
5 METODOLOGIA.....	65
5.1 A BIBLIOTECA TENSORFLOW PARA <i>MACHINE LEARNING</i>	65
5.2 GERAÇÃO DAS OBSERVAÇÕES DA PORTADORA L2 POR MEIO DE RNAs	66
5.2.1 Parte 1 – Estimativa das observáveis da portadora L2 em estações RBMC	67
5.2.2 Parte 2 – Geração das observáveis da portadora L2 em dispositivos móveis de baixo custo	70

5.2.3 – Fluxograma das etapas de elaboração da proposta	74
6 RESULTADOS E DISCUSSÕES	75
6.1 IMPLEMENTAÇÃO E SELEÇÃO DAS RNAs.....	75
6.1.1 Modelo de RNA para a código da portadora	76
6.1.2 Modelo de RNA para a fase da portadora.....	81
6.2 TREINAMENTO E VALIDAÇÃO DAS RNAs.....	84
6.2.1 Desempenho da RNA do código da portadora L2	85
6.2.2 Performance da RNA da fase da portadora L2	85
6.2.3 Resumo dos processos de aprendizagem (tempo e épocas) das RNAs.....	86
6.3 PROCESSAMENTO DOS DADOS GPS	87
6.3.1 Processamento relativo para a estação de São Carlos (EESC da RBMC) – Etapa 1 da Metodologia	88
6.3.2 Influência da memorização excessiva (<i>overfitting</i>) durante o treinamento das RNAs no processamento dos dados GPS.....	93
6.3.3 Processamento PPP com smartphone Android (marcos SAT 93509 e 93670) – Etapa 2 da Metodologia	95
7 CONSIDERAÇÕES FINAIS	99
7.1 SUGESTÕES PARA TRABALHOS FUTUROS	101
REFERÊNCIAS	103
APÊNDICE A – CÓDIGO GENÉRICO DA MLP.....	109
ANEXO A – RELATÓRIOS DE PROCESSAMENTO – MÉTODO RELATIVO DO LEICA GEO OFFICE V. 5	113
ANEXO B – RELATÓRIOS DE PROCESSAMENTO – MÉTODO PPP DA SOLUÇÃO ON-LINE DO IBGE.....	135

1 INTRODUÇÃO

Ao longo dos anos, o posicionamento por satélites artificiais¹ através da geotecnologia GNSS ganhou importante espaço na área de Geomática. Dentre os sistemas que fazem parte desta ferramenta, pode-se destacar o *Global Positioning System* (GPS). Desenvolvido e operado pelo Governo dos Estados Unidos da América (EUA), é um sistema espacial baseado em rádio navegação por satélite para posicionamento global. Em função de ter sido o primeiro a entrar em funcionamento e possuir a maior constelação em operação (31 unidades)², é objeto de estudo da presente investigação, não deixando de evidenciar, entretanto, a relevância das outras geotecnologias que compõem o GNSS.

Inicialmente, os satélites GPS emitiam apenas os sinais L1 C/A, L1 P(Y) e L2 P(Y). No decorrer dos anos, outras unidades foram lançadas e o desenvolvimento do sistema no segmento espacial se deu, em parte, pela emissão de mais sinais a partir de novos satélites, de maneira a complementar a qualidade do posicionamento de pontos (LEICK; RAPOPORT; TATARNIKOV, 2015; SEGANTINE, 2005). Concomitantemente, o segmento terrestre do sistema foi atualizado e atualmente, além dos receptores de navegação que rastreiam apenas o código da frequência L1, existem dispositivos conhecidos como receptores topográficos, capazes de gerar tanto o código como a fase da portadora L1. Ademais, quando da necessidade de maior precisão e acurácia no posicionamento de pontos, o usuário pode dispor de receptores geodésicos, os quais permitem a geração do sinal nas frequências L1 e L2 ou L1, L2 e L5.

Uma das vantagens dos dispositivos de duas ou mais frequências é a possibilidade de se fazer combinações entre as observáveis de diferentes portadoras, melhorando o posicionamento considerando a aplicação de modelos ionosféricos e troposféricos no processamento dos dados. A determinação do Conteúdo Total de Elétrons (TEC) e dos efeitos do multicaminhamento de sinais é outro benefício da combinação das observações das portadoras L1 e L2, por exemplo.

Por outro lado, alguns aparelhos presentes em nosso cotidiano, como smartphones e tablets, em suas versões mais recentes e equipados com microrreceptores GNSS de baixo custo, também rastreiam o sinal GPS, mas geram somente as observações da portadora L1. Em 2016, a Google liberou o acesso a estes dados, a partir de alguns aparelhos com a versão Nougat (v. 7 – “N”) do sistema operacional Android (BANVILLE; VAN DIGGELEN, 2016; MALKOS,

¹ Neste trabalho, os satélites artificiais serão tratados apenas por satélites.

² Status da constelação em 12/11/2018.

2016). No entanto, a baixa qualidade destas medições, o processo de *duty cycling* e as antenas com pouca capacidade de supressão dos efeitos de multicaminhamento, são algumas limitações que ainda precisam ser superadas para que estes aparelhos possam ser empregados com sucesso e confiabilidade em trabalhos de Geomática.

Buscando melhorar a precisão e a exatidão do posicionamento de pontos realizado por meio de dispositivos de uma frequência e eliminar custos adicionais inerentes à eventual necessidade de utilização de receptores geodésicos, este trabalho tem como objetivo principal propor um método para estimar as observáveis da portadora L2 do sistema GPS por meio de RNAs de múltiplas camadas escondidas³. Os objetivos específicos são:

- Determinar a arquitetura e topologia ótima das RNAs e prever as observações da portadora L2 a partir dos dados da L1 de receptores geodésicos;
- Comparar as soluções de posicionamento obtidas com e sem as observáveis estimadas pela rede;
- Validar o método proposto comparando os resultados alcançados nesta pesquisa com os de trabalhos anteriores; e
- Estimar as observações da portadora L2 a partir das observáveis L1 coletadas por dispositivos móveis equipados com microrreceptores GNSS de baixo custo.

1.1 JUSTIFICATIVA

A relação entre o elevado custo financeiro dos receptores geodésicos e os benefícios proporcionados por estes é um *trade-off*⁴ que deve receber atenção especial por parte do profissional. Neste caso, a estimativa das observáveis GPS com qualidade por meio de uma RNA elimina, em determinadas situações, a necessidade de um dispositivo geodésico, evitando maiores custos ao usuário, e possibilita melhorar a precisão e acurácia das soluções de posicionamento quando da realização de trabalhos com aparelhos de uma frequência. Em adição, gerar as observáveis GPS da portadora L2 a partir de observações obtidas em smartphones e tablets pode representar um grande avanço para o estabelecimento preciso de pontos com esses dispositivos, permitindo a sua aplicação em trabalhos profissionais, como

³ Nesta pesquisa, as camadas escondidas poderão também ser tratadas como intermediárias.

⁴ Situação em que ocorre um conflito de escolha.

aqueles relacionados aos Sistemas de Informações Geográficas (SIGs). É importante realçar que para a RNA estimar as observáveis da portadora L2 são necessárias, para o treinamento do modelo, amostras de observações da L1 e L2. Portanto, esta investigação não pretende desqualificar ou desestimular a utilização de receptores geodésicos.

Outrossim, conforme a revisão bibliográfica, os pesquisadores que estimaram as observáveis do sistema GPS por meio de RNAs usaram apenas modelos superficiais⁵. Embora somente redes de uma camada intermediária tenham sido empregadas, não existe uma topologia ideal definida na literatura, sendo a determinação da quantidade de camadas e neurônios escondidos uma questão aberta e que deve ser estudada para cada situação, com testes empíricos até se encontrar a topologia mais adequada. Logo, são desconhecidos os possíveis benefícios do acréscimo de camadas intermediárias para a solução deste problema e, de modo geral, objetiva-se confirmar a hipótese de que aplicando-se uma rede mais profunda, seja possível aprimorar os resultados obtidos até o momento, tornando o processo de estimação mais eficiente, tanto do ponto de vista de tempo de treinamento da ferramenta como da qualidade das observáveis geradas.

Neste contexto, a presente pesquisa propõe a elaboração de um método fundamentado em RNAs capaz de prever com sucesso as observações da pseudodistância e da fase da portadora L2 do sistema GPS, de modo a possibilitar que usuários de dispositivos de uma frequência (receptores topográficos ou até mesmo smartphones e tablets) sejam beneficiados com melhores resultados em suas soluções de posicionamento.

Finalmente, é importante destacar que a implementação da RNA ocorreu através da biblioteca TensorFlow, criada pela empresa Google e lançada em 2015 para computação numérica de alta performance. A ferramenta fornece suporte para trabalhos de *Machine Learning* e *Deep Learning*, permite grande flexibilidade e nesta investigação foi adotada na linguagem Python. De acordo com a revisão bibliográfica sobre o assunto, a biblioteca TensorFlow ainda não foi usada, talvez em função de seu recente lançamento.

⁵ Neste trabalho, redes com uma camada intermediária serão tratadas como superficiais, enquanto que topologias profundas designarão redes com duas ou mais camadas escondidas.

1.2 ESTRUTURA DA DISSERTAÇÃO

O presente trabalho encontra-se estruturado da seguinte forma: no Capítulo 1 é apresentada uma breve introdução, com a contextualização do tema, os objetivos da pesquisa e a justificativa; o Capítulo 2 expõe a revisão bibliográfica realizada tanto em relação às RNAs quanto ao posicionamento de pontos por satélites com receptores de baixo custo, enquanto que os Capítulos 3 e 4 contêm a revisão da literatura de GPS e RNAs, respectivamente. O Capítulo 5 detalha a metodologia proposta, a qual é dividida em duas partes principais, e o Capítulo 6 apresenta os resultados e discussões. Por fim, o Capítulo 7 contém as considerações finais e sugestões para trabalhos futuros.

2 REVISÃO BIBLIOGRÁFICA

Este trabalho requer a união de duas áreas de conhecimento: de um lado a Geodésia, com um problema de GPS pela Geomática, e de outro a Ciência da Computação, com as RNAs sendo uma possível solução. Em razão desta associação, tornou-se necessário detalhar o estado da arte de RNAs e suas aplicações na área de Geodésia e afins. É importante destacar ainda os trabalhos que avaliaram o hardware GNSS de baixo custo instalado em dispositivos móveis e a possibilidade de posicionamento preciso com eles, pois um dos propósitos desta pesquisa é melhorar as soluções com smartphones e tablets.

Começando pela temática de RNAs, Mcculloch e Pitts (1943) desenvolveram o conceito do primeiro modelo artificial de um neurônio biológico, exibindo suas capacidades computacionais e os teoremas que serviram como respaldo para a corroboração de suas ideias. Os autores buscaram representar o comportamento de uma rede de neurônios, mas nada foi desenvolvido no sentido de técnicas ou métodos capazes de treiná-la e fazer com que aprenda. Seis anos mais tarde, Hebb (1949) propôs a primeira regra de aprendizado para RNAs e posteriormente, Rosenblatt (1958) elaborou um novo modelo, denominado Perceptron, capaz de aprender com um professor (*supervised learning* – treinamento supervisionado) e reconhecer padrões simples, tendo sido proposto para ilustrar as propriedades fundamentais de um sistema inteligente. Nos anos seguintes, Widrow e Hoff (1960) criaram uma regra de aprendizado para minimização dos erros de uma RNA, fundamentada no gradiente descendente e denominada regra Delta, também conhecida como algoritmo de aprendizado *Least Mean Square* (LMS).

A partir destes avanços, inúmeros trabalhos pioneiros surgiram e a neurocomputação ganhou força, até que uma pesquisa fez as investigações relacionadas ao tema perderem impulso: Minsky e Papert (1969) identificaram limitações na capacidade das RNAs com apenas uma camada de identificar e aprender relações entre entradas e saídas de funções lógicas simples, demonstrando que poderiam resolver apenas problemas linearmente separáveis. Consequentemente, durante a década de 70, a quantidade de pesquisas com RNAs apresentou forte queda e pouco foi desenvolvido. No entanto, a proposição de Hopfield (1982) de uma RNA recorrente deu à área destaque novamente e o interesse pelo tema motivou inúmeros novos trabalhos. A proposta do algoritmo *back-propagation* (RUMELHART; HINTON; WILLIAMS, 1986), o qual tornou possível o treinamento de RNAs com mais de uma camada, o desenvolvimento de algoritmos de otimização mais eficientes e os avanços computacionais

ocorridos nesta época, podem ser considerados os principais fatores consagradores da retomada definitiva das pesquisas no assunto.

Desde então, várias investigações de caráter teórico foram desenvolvidas, podendo-se destacar a proposição do algoritmo de aprendizado baseado no método Levenberg-Marquardt (HAGAN; MENHAJ, 1994), a criação do algoritmo de otimização para treinamento de RNAs, denominado Adam (KINGMA; BA, 2014) e a técnica de regularização *dropout* para evitar *overfitting* de modelos mais complexos, apresentada em Hinton et al. (2012) e Srivastava et al. (2014).

Por outro lado, várias aplicações práticas vêm sendo realizadas com RNAs nas mais diversas áreas de estudo, tais como na Medicina, Biologia, Finanças e Economia, Farmácia, Engenharias, Geodinâmica e Geodésia. Entre as pesquisas desenvolvidas, existe uma corrente que relaciona RNAs aos inúmeros segmentos da Geodinâmica. Kavzoglu e Saka (2005) por exemplo, fizeram uso de uma rede do tipo *feedforward*, com o algoritmo de treinamento *back-propagation*, para modelar a superfície geoidal em uma região do Peru. Os resultados obtidos pelos pesquisadores indicaram que RNAs podem produzir saídas tão boas quanto às geradas por métodos convencionais, sendo que as superfícies geoidais baseadas nesta ferramenta possuem como principal vantagem menores distorções.

No Brasil, Reinke et al. (2007) determinaram a superfície geoidal por meio de uma RNA com três camadas intermediárias e Veronez et al. (2011) propuseram uma metodologia alternativa para interpolar as alturas geoidais do Estado de São Paulo com um modelo de duas camadas escondidas. Ambos concluíram que a ferramenta produziu bons resultados e, no caso de Veronez et al. (2011), as saídas da rede foram melhores em comparação às produzidas pelo software MAPGEO2004, do Instituto Brasileiro de Geografia e Estatística (IBGE).

Várias investigações relacionadas à ionosfera em conjunto com RNAs foram conduzidas. Ma et al. (2005) utilizando um modelo com quatro camadas intermediárias e 27 neurônios, desenvolveram uma tomografia tridimensional para reconstruir a densidade eletrônica da ionosfera. Na África do Sul, Habarulema, Mckinnell e Cilliers (2007) desenvolveram um modelo com base em RNAs para predição dos valores de TEC, analisando o seu desempenho em três locais distintos. A ferramenta, com uma camada escondida, estimou com exatidão as saídas, produzindo em determinadas situações valores mais acurados do que aqueles obtidos pelo *International Reference Ionosphere* (IRI). Os autores realçaram,

entretanto, que para a criação de um sistema totalmente representativo, seriam necessários mais dados e de maior qualidade para treinamento da rede.

Recentemente, Ferreira et al. (2017) avaliaram o uso de uma RNA do tipo MLP, com uma camada intermediária e 10 neurônios, para estimar os valores de TEC no Brasil, em três setores diferentes do país. Hernández-Pajares, Juan e Sanz (1997), Tulunay et al. (2006) e Leandro e Santos (2007) também atentaram-se em determinar este parâmetro com RNAs nas mais diversas regiões do globo.

Outros trabalhos buscaram mapear a ionosfera no sentido de determinar algumas de suas características e comportamento através de RNAs, como o de Willisroft e Poole (1996) que aplicaram a ferramenta para determinar os melhores parâmetros de predição da frequência crítica da camada F2 da ionosfera (f_oF_2), bem como os próprios valores de f_oF_2 . Os pesquisadores concluíram que RNAs representam uma forma conveniente e confiável de modelar os parâmetros ionosféricos. Altinay, Tulunay e Tulunay (1997), testando várias topologias, voltaram-se para a elaboração de um modelo eficiente de previsão das variações nos valores de f_oF_2 , criando uma proposta capaz de capturar rapidamente as alterações na frequência e gerar respostas muito próximas das desejadas (erro médio absoluto de 0,402MHz).

Neste mesmo caminho, Cander et al. (1998) coordenaram um estudo com o objetivo de prever o TEC e o parâmetro f_oF_2 uma hora adiante. A estimativa dos valores de f_oF_2 24 horas à frente também já foi realizada em períodos com altos índices de atividade solar, com uma RNA do tipo *feedforward*, uma camada escondida, 10 neurônios e treinada pelo algoritmo *back-propagation* (WINTOFT; CANDER, 2000). Os pesquisadores consideraram os resultados promissores e quando comparadas a outros métodos, as RNAs produziram saídas mais próximas das desejadas em boa parte do tempo.

Na Geomática e agora relacionado ao segmento de posicionamento de pontos com o sistema GNSS, RNAs foram usadas na estimação das correções das observações para levantamento diferencial, em inglês *Differential Global Positioning System* (DGPS) (MOSAVI, 2004). Nesta pesquisa, o modelo de rede tinha como função de ativação dos neurônios uma função Wavelet, daí o nome *Wavelet Neural Network* (WNN). Outrossim, Sang, Kubik e Zhang (1997), Mosavi (2006) e Indriyatmoko et al. (2008) também aplicaram RNAs para estimar as correções DGPS. Deve-se destacar que objetivo principal em Mosavi (2006) era aplicar RNAs para melhorar o posicionamento de receptores de baixo custo, criando-se assim um paralelo com o presente trabalho.

Jwo e Chin (2002) utilizaram uma RNA superficial para determinar o parâmetro de Diluição Geométrica da Precisão (GDOP) e Jwo e Lai (2007) conduziram testes com várias arquiteturas e topologias, buscando determinar a configuração ideal para estimar os valores de GDOP. Os resultados mostraram que todas as redes candidatas atenderam às expectativas quanto à exatidão, mas aquelas treinadas pelo algoritmo *back-propagation* apresentaram maior tempo de aprendizado. Ademais, uma RNA Wavelet do tipo recorrente, do inglês *Recurrent Wavelet Neural Network* (RWNN), foi implementada em Mosavi (2007) para reduzir os ruídos dos dados de tempo de receptores GPS e modelar os erros desta origem.

RNAs ainda foram empregadas para garantir e até mesmo melhorar o posicionamento durante o bloqueio de sinal GPS. Semeniuk e Noureldin (2006), por exemplo, criaram um método alternativo com base em uma RNA que estima os erros de velocidade e posição de um sistema de navegação inercial, para corrigir e aprimorar o posicionamento em locais onde o sistema GPS não esteja disponível. Mais recentemente, um híbrido entre uma WNN e o Filtro de Kalman foi proposto na tentativa de melhorar o posicionamento por satélites também durante este tipo de situação (CHEN et al., 2013). Novamente, utilizando os algoritmos em conjunto com um sistema de navegação inercial, foi possível compensar os erros durante a perda de sinal GPS e a proposta mostrou-se bastante eficaz.

Aproximando-se do tema deste trabalho, Silva (2003) procurou melhorar o posicionamento com receptores de uma frequência, criando um método para se estimar as observáveis GPS da portadora L2 por meio de RNAs. Inúmeros experimentos foram realizados no sentido de se determinar uma topologia adequada para solução do problema e os dados mais apropriados para treinamento. O modelo selecionado para geração da fase da portadora foi uma rede MLP com uma camada escondida e 6 neurônios. Para a estimação das observações do código, optou-se por uma rede de mesma arquitetura, mas com 30 neurônios, destacando-se que em determinados momentos, segundo o pesquisador, foi necessário aumentar o número de neurônios para garantir a sua capacidade de generalização. Ambas as configurações foram implementadas no software MATLAB 6.1 e treinados pelo algoritmo Levenberg-Marquardt, atingindo até 5.000 iterações.

Confirmando a hipótese inicial de sua investigação, os resultados de Silva (2003) apontaram que a ferramenta é capaz de modelar com sucesso o comportamento das observáveis, mesmo por um curto período de tempo. Outrossim, foi possível melhorar as soluções de posicionamento utilizando as observáveis artificiais e eliminar perdas de ciclos para a fase L2.

Entretanto, o autor sugeriu como trabalhos futuros uma árvore de testes ainda maior que a executada em seu trabalho, avaliando-se um universo mais amplo de possíveis topologias.

Leandro, Silva e Santos (2007) também coordenaram uma pesquisa relacionada à esta investigação, com o objetivo de identificar a melhor forma de se alimentar uma RNA com observações do sistema GPS. Determinou-se que a diferença entre épocas consecutivas é a maneira mais eficiente de se apresentar os dados à rede, quando do treinamento da fase da portadora, eliminando o termo da ambiguidade e diminuindo a ordem de grandeza dos valores. Para a pseudodistância, o processo de truncagem inversa⁶ foi considerado o mais apropriado.

Por fim, Mazzetto (2017) adotando as mesmas topologias indicadas por Silva (2003) e implementando-as também no software MATLAB, propôs um método no qual somente os sinais com maior potência e menos ruídos deveriam ser empregados durante o treinamento da RNA. Além disso, apenas os dados obtidos em 4 estações próximas ao receptor onde se deseja estimar as observáveis da portadora L2 foram utilizados, pois, teoricamente, experimentam os mesmos efeitos atmosféricos.

Para o tratamento dos dados, Mazzetto (2017) elaborou um programa para juntar todas as amostras de treinamento e tratá-las de acordo com a necessidade do usuário. O software, nomeado RINEX ADAPTER, permite ainda produzir novos arquivos RINEX com as observáveis geradas pela rede. No tocante ao treinamento dos modelos, os tempos variaram de 4 a 8 minutos para a fase da portadora e de poucos segundos para o código, sendo que em determinados momentos, foram necessárias até 15.000 iterações para que o processo fosse interrompido. É importante realçar ainda que para o código da portadora, em algumas situações os valores de *Mean Squared Error* (MSE) de validação ficaram bem altos, não convergindo como esperado.

Mazzetto (2017) conseguiu aumentar o tempo de predição das observáveis GPS e, de modo geral, melhorar a exatidão das soluções de posicionamento, restringindo os sinais de acordo com a potência do sinal e também utilizando observações geradas em estações próximas à de teste. Contudo, o pesquisador concluiu que com a capacidade de processamento dos

⁶ Este procedimento seleciona apenas os últimos “ n ” dígitos de um determinado número, sendo “ n ” definido de acordo com as necessidades do problema. Por exemplo: tem-se 1.542.817,965; o processo de truncagem inversa com $n = 6$ extrairá deste número apenas os seis dígitos da direita para a esquerda, resultando em 817,965.

computadores atuais, a técnica de *Deep Learning* poderia ser testada, visando implementar redes profundas na tentativa de extrair mais informações do sistema.

A revisão bibliográfica realizada até o momento demonstra que os trabalhos utilizaram apenas RNAs de uma camada intermediária para estimar os valores das observações da portadora L2. Segundo Hornik, Stinchcombe e White (1989), uma MLP superficial pode aproximar qualquer função em determinando nível de acurácia. No entanto, Bengio e Lecun (2007) afirmam que, embora redes com uma camada escondida tenham suas vantagens e alguns teoremas provem sua eficácia, os modelos mais profundos podem representar de uma maneira mais eficiente determinados sistemas, pois conseguem aprender abstrações de nível inferior (características das características), principalmente em situações de maior complexidade. Em adição, Goodfellow, Bengio e Courville (2016) mostraram a partir de testes empíricos que RNAs com duas ou mais camadas escondidas possuem melhor capacidade de generalização em relação aos modelos mais simples. Assim, são desconhecidos os benefícios das redes de múltiplas camadas intermediárias para a solução do problema em questão.

No que diz respeito ao posicionamento de pontos por satélites com receptores de baixo custo, pode-se dizer que, nos dias atuais, o sistema está disponível em nossas vidas a todo instante por meio de antenas e microrreceptores GNSS instalados em smartphones e tablets. Em 2019, o número de usuários de telefones móveis ultrapassará 4,6 bilhões (EMARKETER, 2016), fazendo com que boa parte da população seja beneficiada com os serviços de localização. Nestes aparelhos, o posicionamento pode ser obtido através da comunicação dos microrreceptores GNSS com os satélites, baseando-se apenas nas observáveis da pseudodistância e gerando soluções de navegação com exatidão de poucos metros à dezenas de metros (JONES; MARZEN; CHAPPELKA, 2015; PETOVELLO, 2014; SCHAEFER; WOODYER, 2015; ZANDBERGEN, 2009; ZANDBERGEN; BARBEAU, 2011; ZHIZHONG MA et al., 2013).

Até recentemente, apenas a pseudodistância estava disponível aos desenvolvedores de aplicativos. Porém, tanto o código como a fase da portadora sempre foram produzidos pelos receptores GNSS de dispositivos móveis. Com um smartphone Android rodando uma versão do sistema operacional especialmente modificada pela fabricante de microrreceptores GNSS Broadcom para acesso às observações, Humphreys et al. (2016) geraram arquivos RINEX com a pseudodistância e a fase da portadora a partir de um Samsung Galaxy S5. Explorando estes dados, os autores identificaram que as antenas instaladas nos aparelhos atuais são alguns dos obstáculos a serem vencidos para o posicionamento de pontos com precisão e acurácia, sendo

altamente sensíveis aos efeitos do multicaminhamento. Em relação às medições da fase da portadora, estas sofrem anomalias que podem dificultar o estabelecimento de pontos. Mesmo assim, o smartphone foi capaz de produzir as observáveis da pseudodistância de qualidade e os pesquisadores concluíram que este pode suportar soluções com exatidão da ordem de centímetros.

Em maio de 2016, a Google finalmente decidiu liberar o acesso total às observações GNSS brutas a partir de alguns smartphones e tablets com sistema operacional Android “N”, estando agora disponíveis para os desenvolvedores de aplicativos (BANVILLE; VAN DIGGELEN, 2016; MALKOS, 2016). A partir desta novidade, estudos foram conduzidos com o objetivo de avaliar o posicionamento com os aparelhos. Em Banville e Van Diggelen (2016) por exemplo, as observáveis foram coletadas durante 3 minutos por um smartphone Samsung Galaxy S7, identificando-se mais uma vez que a antena GNSS é altamente suscetível ao multicaminhamento de sinais, devido à sua polarização linear. Em adição, notaram-se ruídos da ordem de metros até mesmo no satélite com maior valor de C/N_0 e, em geral, a intensidade do sinal é 10db-Hz menor em comparação àquela observada em antenas e receptores geodésicos, prejudicando a qualidade das medições. Apesar destas limitações, Banville e van Diggelen (2016) confirmaram a possibilidade de posicionamento preciso com smartphones, mas realçaram que o processo de *duty cycling*, a baixa qualidade das antenas GNSS e dos osciladores *Temperature-Compensated Crystal Oscillator* (TCXO), são as principais barreiras para estes se tornarem competitivos e equiparáveis aos receptores GNSS de baixo custo disponíveis no mercado.

Em outro trabalho, Realini et al. (2017) utilizaram as observações GNSS coletadas a partir do tablet Google HTC Nexus 9 para analisar a precisão do posicionamento com o único modelo no mercado atual capaz de desativar o processo de *duty cycling*. Aplicando o método relativo, com linhas bases curtas (até 8 quilômetros), os resultados indicaram precisão da ordem de 4,8 a 10 centímetros e os testes demonstraram empiricamente acurácia de decímetros, já que as observáveis obtidas apresentam qualidade similar aquelas rastreadas por receptores de uma frequência e custo acessível.

Na China, uma investigação foi conduzida para avaliar as medições GNSS obtidas em dispositivos Android (Google HTC Nexus 9), tanto no modo estático como cinemático, comparando as soluções de posicionamento com um receptor geodésico (ZHANG et al., 2018). Os pesquisadores concluíram que o sinal modulado tem a relação C/N_0 , em geral, 10db-Hz menor em comparação a um receptor de maior qualidade, como já descrito em trabalhos

anteriores, e possuem maior quantidade de ruídos até mesmo nos satélites mais altos. Outrossim, em contraste com o que ocorre em receptores GNSS profissionais, encontrou-se baixa correlação entre o *Signal to Noise Ratio* (SNR) e o ângulo de elevação dos satélites. Apesar disso, foi possível atingir precisão de decímetros nas coordenadas horizontais utilizando-se a fase da portadora em conjunto com a pseudodistância. Liu et al. (2017) também analisaram as observáveis GPS obtidas no tablet Google HTC Nexus 9 e a possibilidade de posicionamento preciso e acurado com estes receptores.

Por fim, no trabalho de Dabove e Di Pietra (2018) realizou-se o posicionamento cinemático em tempo real com os smartphones Samsung Galaxy S8+ e Huawei P10 Plus. A técnica de estabelecimento de pontos elaborada pelos autores é dependente de uma rede de monitoramento contínuo para o fornecimento das correções diferenciais, isto é, necessita de um receptor geodésico ativo simultaneamente e próximo ao local a ser levantado. Como esperado, em função dos ruídos presentes nas observáveis e da má qualidade do hardware GNSS, não foi possível fixar a ambiguidade corretamente. Entretanto, os resultados indicaram a possibilidade de realizar o posicionamento em tempo real com os dispositivos Android, obtendo-se acurácia menor que 1m e precisão de poucos centímetros.

Como algumas pesquisas sugerem, é possível atingir precisão e exatidão no posicionamento de pontos com aparelhos móveis. Porém, observa-se que além das limitações referentes ao hardware GNSS presente em smartphones e tablets, todos os dispositivos rastreiam apenas a frequência L1 quanto ao sistema GPS, tornando as soluções de posicionamento dependentes de modelos ionosféricos para redução dos efeitos desta origem. Observando apenas a portadora L1, estes receptores não podem nem mesmo ser empregados em atividades mais elementares, como na determinação dos valores de TEC e na caracterização do multicaminhamento de sinais.

De modo geral, existe a necessidade de se rastrear uma segunda frequência em conjunto com a L1 e obter as suas respectivas observáveis, especialmente quando se deseja obter posicionamento acurado com dispositivos de baixo custo que experimentam os mais diversos tipos de efeitos, originados de várias fontes de erros. Logo, a utilização de um modelo de RNA adequado para estimar os dados da portadora L2, capaz de extrair as características do processo de maneira mais eficiente do que uma MLP superficial e ser tolerante aos ruídos existentes nos sinais de entrada, representa um passo importante para o aprimoramento das soluções pós-processadas com aparelhos de uma frequência. A aplicação do método sugerido nesta

investigação pode significar, portanto, a eliminação de custos adicionais do usuário em algumas atividades de Geomática, viabilizando o uso de smartphones e tablets, totalmente acessíveis.

3 SISTEMA GLOBAL DE POSICIONAMENTO (GPS)

Criado pelo Departamento de Defesa dos Estados Unidos da América (DoD) com o objetivo inicial de proporcionar serviços de navegação e posicionamento aos militares, o GPS é uma geotecnologia fundamentada em rádio navegação por satélite, sendo que atualmente está disponível para qualquer usuário civil com acesso a um receptor. O sistema permite determinar a distância entre as antenas dos satélites e a do receptor através da conversão dos sinais recebidos em observações, obtendo-se a posição tridimensional de qualquer ponto de interesse na superfície terrestre com relação a um sistema de referência definido (LEICK; RAPOPORT; TATARNIKOV, 2015; SEGANTINE, 2005).

Neste capítulo, são abordados os assuntos relacionados ao sistema GPS, bem como os conceitos básicos do sinal, as origens dos erros nas observações, os tipos de receptores e suas características principais e os métodos de posicionamento utilizados nesta pesquisa. O leitor que tiver interesse em informações mais detalhadas poderá buscá-las em materiais específicos, a saber: Segantine (2005), Hoffman-Wellenhof, Lichtenegger e Wasle (2008), Monico (2008) e Leick, Rapoport e Tatarnikov (2015).

3.1 O SINAL GPS

Os satélites GPS transmitem informações codificadas em determinadas frequências de ondas eletromagnéticas (portadoras) que são recebidas pelas antenas. Conectados à estas, os receptores geram uma resposta similar à obtida, comparando os sinais para determinação de sua posição tridimensional. Uma frequência fundamental unidirecional, denominada f_0 (10,23MHz), é emitida por todos os satélites. A partir desta, são geradas as outras bandas do sinal, como pode ser visto na Tabela 1 e na Figura 1.

Tabela 1 - Bandas de frequência do sinal GPS

Portadora	Fator ($\cdot f_0$)	Frequência (MHz)	Comprimento de onda (cm)
L1	154	1.575,42	19,0
L2	120	1.227,60	24,4
L5	115	1.176,45	25,5

Fonte: adaptada de Leick, Rapoport e Tatarnikov (2015).

Figura 1 - Representação genérica da estrutura dos sinais GPS

Fonte: adaptada de Silva e Segantine (2015).

Deve-se destacar que em um primeiro momento, os satélites GPS transmitiam as informações apenas nas frequências L1 e L2. Com a modernização do sistema no segmento espacial, algumas unidades em órbita passaram a apresentar um terceiro sinal civil: o L5. Futuros satélites já em produção, serão classificados como bloco III e deverão transmitir um quarto sinal civil (L1C), com o objetivo de melhorar a recepção do sinal em cidades e em locais bastante obstruídos por construções e vegetação (NATIONAL COORDINATION OFFICE FOR SPACE-BASED POSITIONING NAVIGATION AND TIMING, 2015).

A combinação linear entre as observações das portadoras L1 e L2 resulta no sinal L3, também conhecido como *iono-free*, por ser capaz de reduzir drasticamente os efeitos da ionosfera que o sinal sofre quando se propaga por esta camada atmosférica até atingir a antena do receptor, provendo melhores resultados para as soluções de posicionamento.

Dois parâmetros podem ser utilizados para descrever a intensidade do sinal GPS. De acordo com Leick, Rapoport e Tatarnikov (2015), o primeiro valor é o SNR, que representa a diferença entre a potência do sinal e a do ruído, em uma determinada largura de banda. É expresso em decibéis e dependente das características do receptor quanto a sua qualidade, capacidade de rastreamento e aquisição de dados. O outro é o *Carrier to Noise Ratio* (C/N_0), indicado em decibéis-Hertz e com magnitude comum variando de 37 a 45db-Hz para o sinal GPS. Segundo Rapiński, Tomaszewski e Kowalski (2014), este parâmetro permite determinar a intensidade do sinal modulado do satélite e a densidade de ruídos observados pelo receptor, ou seja, indica a relação entre a potência da portadora e a do ruído, por unidade de largura de banda. A informação contida nos valores de C/N_0 é utilizada para determinação da qualidade do sinal.

3.2 OBSERVÁVEIS GPS

Leick, Rapoport e Tatarnikov (2015) afirmam que a pseudodistância e a fase da portadora são as observáveis GPS mais importantes para o posicionamento. Inicialmente, as primeiras soluções de navegação usavam apenas a pseudodistância, obtida com base na medição do tempo de percurso da onda eletromagnética entre a antena do satélite e a do receptor, conhecendo-se a época de saída do código, a época de chegada no receptor e a velocidade de propagação do sinal, que é igual a velocidade da luz no vácuo.

A expressão matemática da pseudodistância precisa considerar, além da distância geométrica, os erros dos relógios do receptor e do satélite, os efeitos da atmosfera (atrasos na ionosfera e troposfera), os ruídos gerados internamente no receptor e no satélite e também o multicaminhamento do código, sendo a expressão completa dada por Leick (2004) e apresentada na Equação 1:

$$P_{k,1}^p(t_k) = \rho_k^p(\hat{t}^p) - c dt_{-k} + c d\bar{t}^p + I_{k,1,P}^p(t_k) + T_k^p(t_k) + \delta_{k,1,P}^p(t_k) + \varepsilon_{1,P} \quad (1)$$

Em que:

ρ_k^p = distância geométrica no vácuo, calculada com base na posição do satélite p e do receptor k , considerando a rotação da terra durante o tempo de propagação do sinal;

dt_{-k} = desvio do tempo nominal (t_k) de chegada do código em relação ao tempo verdadeiro ($\hat{t}_k$) desta chegada, ou seja, o erro existente na leitura do relógio do receptor k , na época em que o código entrou na antena, em relação ao $\hat{t}_k$;

dt^p = desvio do tempo nominal (t^p) de transmissão do código em relação ao tempo verdadeiro ($\hat{t}^p$) desta transmissão, ou seja, o erro existente na leitura do relógio do satélite p , na época em que o código é transmitido na antena deste satélite, em relação ao $\hat{t}^p$;

c = velocidade da luz;

$I_{k,1,p}^p$ = atraso ionosférico do código-P na portadora L1, sendo este valor sempre positivo e dependente das condições ionosféricas ao longo do percurso do sinal e da frequência;

T_k^p = atraso troposférico que depende das condições troposféricas e é independente da frequência. Também sempre será um valor positivo;

$\delta_{k,1,p}^p$ = atrasos dos hardwares do satélite e do receptor e efeitos do multicaminhamento;

$\varepsilon_{1,p}$ = ruídos nas medições da pseudodistância (aproximadamente 30 cm para o código-P e valores mais altos para o código C/A, dependendo da tecnologia utilizada).

A pseudodistância utiliza dois códigos, os quais são modulados para as duas portadoras: o *Coarse Acquisition* (C/A) e o código-P. O C/A tem comprimento de onda efetivo de aproximadamente 300 metros e é propositalmente omitido da frequência L2. Por outro lado, o código-P tem comprimento de onda efetivo em torno de 30 metros e está modulado nas duas portadoras. No entanto, atualmente o código-P está criptografado para o código-Y e disponível apenas para usuários autorizados (HOFMANN-WELLENHOF; LICHTENEGGER; WASLE, 2008).

Entendida como a diferença de fases da onda emitida pelo satélite e da onda gerada internamente no receptor, a fase da portadora, em conjunto com a pseudodistância, é aplicada em soluções que exigem maior precisão e acurácia (SEGANTINE, 2005). A fase da portadora, em unidades de comprimento, pode ser definida por meio da Equação 2 (LEICK; RAPOPORT; TATARNIKOV, 2015):

$$\phi_{k,1}^p(t_k) = \rho_k^p(\hat{t}^p) + \lambda_1 N_k^p - c dt_k + c d\bar{t}^p + I_{k,1,\phi}^p(t_k) + T_k^p(t_k) + \delta_{k,1,\phi}^p(t_k) + \varepsilon_{1,\phi} \quad (2)$$

Em que:

ρ_k^p = distância geométrica no vácuo, calculada com base na posição do satélite p e do receptor k , considerando a rotação da terra durante o tempo de propagação do sinal;

λ_1 = comprimento da onda portadora L1;

N_k^p = incógnita que representa a ambiguidade inteira;

$I_{k,1,\phi}^p$ = avanço ionosférico da fase da portadora L1, sendo este valor sempre negativo e dependente das condições ionosféricas ao longo do percurso do sinal e da frequência;

$\delta_{k,1,\phi}^p$ = atrasos dos hardwares do satélite e do receptor e efeitos do multicaminhamento na fase da portadora L1;

$\varepsilon_{1,\phi}$ = ruídos da fase da portadora (menor que 0,01 ciclos).

Observa-se que o subscrito ϕ indica que as respectivas quantidades estão em unidades de comprimento. A fase da portadora expressada em número de ciclos será tratada neste trabalho como φ . Destaca-se também neste momento o conceito de ambiguidade: este representa o número inteiro de ciclos da fase da portadora, referente a primeira época de rastreo e que se mantém constante durante o período de observação, desde que não ocorram perdas de sinal (LEICK; RAPOPORT; TATARNIKOV, 2015).

3.2.1 O formato RINEX

Os dados observados e gerados pelo receptor GPS (ou GNSS) são armazenados em um formato binário específico de cada fabricante. Para compatibilizar e facilitar o processamento das observações coletadas por aparelhos de diferentes marcas, adotou-se um padrão conhecido como RINEX, do inglês *Receiver Independent Exchange Format*.

O formato RINEX é composto por três arquivos com codificação *American Standard Code for Information Interchange* (ASCII):

1. Dados de observações;

2. Dados meteorológicos (opcional);
3. Mensagem de navegação.

Cada arquivo de observação, por exemplo, contém uma seção inicial (cabeçalho), com informações gerais, a saber: data e horário, estação receptora, número de satélites observados, versão do arquivo (2 ou 3), etc. Em seguida, são registradas as épocas de observação, quantidade e tipo dos satélites e as suas respectivas observáveis (fase e código das portadoras, em ciclos e metros respectivamente). Atualmente, é comum a disponibilização dos RINEX de observação através de arquivos compactados no formato HATANAKA, diminuindo os seus tamanhos. Maiores informações acerca do padrão e também de como descompactá-lo encontram-se em Hatanaka (2008).

Os arquivos RINEX podem ser visualizados por simples editores de textos, como os softwares Bloco de Notas do Windows e Notepad++. A seguir, a Figura 2 apresenta um exemplo de um RINEX de observação gerado no receptor de dupla frequência da estação EESC da Rede Brasileira de Monitoramento Contínuo dos Sistemas GNSS (RBMC).

Figura 2 - Fac-símile de um arquivo RINEX de observação (estação RBMC-EESC do dia 25/09/2018)

```

1      2.11      OBSERVATION DATA      M (MIXED)      RINEX VERSION / TYPE
2      teqc      2018Jun8      20180926 06:30:13UTC      CPGM / RUN BY / DATE
3      EESC
4      41694M001      MARKER NAME
5      RBMC      IBGE/CGED      MARKER NUMBER
6      1700144      LEICA GR10      1.00/6.112      OBSERVER / AGENCY
7      13194-019      LEIAR10      NONE      REC # / TYPE / VERS
8      3967006.9729 -4390247.3691 -2375229.9370      ANT # / TYPE
9      0.0000      0.0000      0.0000      APPROX POSITION XYZ
10     1      1      ANTENNA: DELTA H/E/N
11     10      L1      L2      L5      C1      C2      P2      C5      S1      S2# / TYPES OF OBSERV
12     18      S5      # / TYPES OF OBSERV
13     LEAP SECONDS
14     Linux 2.6.32-573.12.1.x86_64|gcc -static|Linux 64|=+      COMMENT
15     teqc 2018Jun8      RBMC      20180926 06:30:11UTC      COMMENT
16     Forced Modulo Decimation to 15 seconds      COMMENT
17     CODIGO: 99560      Estacao: Sao Carlos      COMMENT
18     2018      9      25      0      0      0.00000000      GPS      TIME OF FIRST OBS
19     END OF HEADER
20     18      9      25      0      0      0.00000000      0      22G31G15G21G20G25G26G10G05G12G29R14R23
21     R13R24R01R15R17R03R02E26E01E21
22     123240234.936 7      96031324.518 7      23451838.340      23451832.920
23     23451832.820      45.850      42.950
24     128028867.254 7      99762766.284 6      24363074.480      24363070.160
25     24363069.120      44.800      41.350
26     111044338.673 8      86528077.74247      21131015.300
27     21131008.180      48.200      44.550
28     114654477.588 7      89341170.36747      21818008.700
29     21818002.360      47.250      42.250
30     109948657.676 8      85674304.298 8      82104556.742 8      20922520.500      20922517.360
31     20922516.680      20922519.140      49.100      48.000      50.200

```

Fonte: elaborada pelo autor (2018).

3.2.2 Diferença de fases

É possível realizar combinações entre as observações da fase da portadora de diferentes estações, satélites ou até mesmo de épocas distintas, obtendo-se alguns benefícios no posicionamento. Destacam-se três processos de combinação: a Simples Diferença (SD) de fases, Dupla Diferença (DD) de fases e Tripla Diferença (TD) de fases.

A SD de fases realizada entre dois receptores elimina os erros provenientes do relógio do satélite e, caso esteja-se aplicando o processo entre dois satélites, os erros do relógio do receptor serão anulados. Pode-se ainda cancelar a ambiguidade realizando-se a SD de fases entre observações de épocas distintas, considerando a não existência de perdas de ciclos. Por outro lado, Hoffman-Wellenhof, Lichtenegger e Wasle (2008) afirmam que a DD de fases, combinando-se dois receptores e dois satélites, elimina os erros oriundos dos relógios, tanto das fontes transmissoras dos sinais como dos dispositivos de recepção, sendo uma das técnicas mais adotadas. Conforme Leick, Rapoport e Tatarnikov (2015), a SD e a DD de fases podem ser definidas por meio das Equações 3 e 4, respectivamente:

$$\varphi_{km}^p(t) = \varphi_k^p(t) - \varphi_m^p(t) \quad (3)$$

$$\varphi_{km}^{pq}(t) = \varphi_{km}^p(t) - \varphi_{km}^q(t) \quad (4)$$

Em que:

$\varphi_k^p(t)$ = É a fase da portadora, em número de ciclos e no tempo t , com relação ao satélite p e ao receptor k ;

φ_m^p = É a fase da portadora, em número de ciclos e no tempo t , com relação ao satélite p e ao receptor m ;

$\varphi_{km}^p(t)$ = É a fase da portadora, em número de ciclos e no tempo t , com relação ao satélite p e aos receptores k e m ;

$\varphi_{km}^q(t)$ = É a fase da portadora, em número de ciclos e no tempo t , com relação ao satélite q e aos receptores k e m .

A Figura 3 expõe o esquema da DD de fases entre satélites e estações, facilitando a compressão do processo:

Figura 3 - Esquema da DD de fases entre dois satélites e duas estações

Fonte: adaptada de Segantine (2005).

Quanto à TD de fases, além da DD, ocorre a combinação entre duas épocas distintas, ou seja, é realizada a diferença de fases entre as estações k e m , para os satélites p e q , nas épocas t_1 e t_2 por exemplo, cancelando-se o termo da ambiguidade.

3.3 ORIGEM DOS ERROS NO POSICIONAMENTO COM O SISTEMA GPS

Inúmeras fontes de erros podem impedir o posicionamento preciso e acurado de pontos com o sistema GPS, sendo que nesta pesquisa somente são descritas aquelas que, geralmente, produzem maiores desvios nas soluções. A seguir, a Tabela 2 apresenta as principais fontes de erros e seus efeitos:

Tabela 2 - Fontes de erros no posicionamento com o sistema GPS

Fonte	Efeito
Satélite	Erro do relógio
	Erro das órbitas
Propagação do sinal	Refração da ionosfera
	Refração da troposfera
Receptor	Variação do centro de fase da antena
	Erro do relógio
	Multicaminhamento

Fonte: adaptada de Hofmann-Wellenhof, Lichtenegger e Wasle (2008).

O sistema GPS determina a posição de uma antena sobre a superfície terrestre com base na estimativa de tempo que o sinal leva para percorrer a distância entre a antena do satélite e a do receptor. Logo, erros originados nos relógios do receptor e dos satélites, por menor que sejam, multiplicados pela velocidade da luz, podem degradar consideravelmente a precisão e acurácia do posicionamento de pontos (SEGANTINE, 2005).

A segunda fonte de erros está relacionada às efemérides, ou seja, à posição orbital dos satélites e às correções dos relógios destes. Segundo Segantine (2005), os satélites transmitem as efemérides que predizem sua posição em uma determinada época t . Se esta estimativa contiver erros, mesmo que da ordem de 3 metros por exemplo, a medição da distância entre a antena do receptor e a do satélite estará incorreta, diminuindo a precisão e acurácia da solução.

Pode-se destacar ainda os atrasos que as portadoras sofrem devido a propagação dos sinais na ionosfera e troposfera. As ondas de rádio, ao percorrem a atmosfera terrestre que não possui homogeneidade entre suas camadas, podem ser influenciadas pelas condições ao longo do caminho. De acordo com Leick, Rapoport e Tatarski (2015), quando os sinais encontram elétrons livres ao longo de seu percurso pela ionosfera, ocorrem atrasos na pseudodistância e avanços na fase da portadora em igual magnitude, gerando erros no posicionamento e degradação da acurácia e precisão.

O multicaminhamento, a quarta fonte de erros descrita nesta seção, é a condição na qual os sinais são refletidos em superfícies na proximidade da antena e chegam à esta por um caminho indireto, isto é, por meio de mais de um percurso natural, gerando assinaturas indesejáveis nas observações da pseudodistância e da fase da portadora. O multicaminhamento

de sinais depende do tipo de material da superfície refletora e também das condições ao redor e próximas à antena (HOFMANN-WELLENHOF; LICHTENEGGER; WASLE, 2008; LEICK; RAPOPORT; TATARNIKOV, 2015).

Existem também as seguintes origens de erros: perdas de ciclos, ruídos no receptor, ruídos nas observáveis e erros no centro de fase da antena.

3.4 RECEPTORES GNSS

Quando o usuário deseja realizar trabalhos de Mensuração e/ou Geodésia utilizando a geotecnologia GNSS, o item de maior custo envolvido no processo de posicionamento é a aquisição do receptor e da antena, principalmente em trabalhos que exijam alta precisão e acurácia, onde é necessária a utilização de equipamentos de dupla ou tripla frequência e, conseqüentemente, de elevado custo financeiro. Nos últimos anos, os receptores evoluíram consideravelmente, acompanhando o desenvolvimento tecnológico e científico. Estes passaram de aparelhos pesados à pequenos dispositivos que, em geral, não ultrapassam poucos quilogramas.

Basicamente, os receptores GNSS são compostos de uma antena, pré-amplificador, um processador de sinal que rastreia o código e a fase da portadora, um oscilador, um microprocessador, memória, display para configuração da seção e suprimento de energia (SEGANTINE, 2005). Os osciladores de quartzo têm função de gerar uma onda com características similares aquela recebida do satélite, podendo ser divididos em duas principais categorias: *Temperature-Compensated Crystal Oscillator* (TCXO), encontrados em dispositivos mais baratos, e *Oven-Controlled Crystal Oscillator* (OCXO), mais estáveis e precisos.

Embora os relógios encontrados nos satélites sejam de partículas atômicas e de qualidade até mesmo superior aos melhores osciladores OCXO, a diferença entre as tecnologias empregadas na fabricação dos relógios dos receptores e dos satélites não permite a sincronização dos tempos de maneira exata, o que acaba resultando no efeito conhecido como erros dos relógios, por isso também o nome de pseudodistância, já que a distância possui um viés.

Os receptores GNSS podem ser classificados quanto ao tipo de sinal que são capazes de observar, podendo-se destacar para uso civil três tipos: os de navegação, os quais recebem apenas a pseudodistância através do código C/A; dispositivos que observam a portadora L1 e também o código C/A (topográficos); e os receptores que rastreiam mais de uma frequência e os seus respectivos códigos (geodésicos) (SEGANTINE, 2005). É importante realçar que a maioria dos dispositivos atuais possuem a capacidade de receber os sinais de todos os satélites do sistema GNSS.

Existe no mercado uma variedade enorme de modelos, marcas e características. Para maior acurácia e precisão no posicionamento de pontos, aplicações geodésicas e monitoramento de estruturas por exemplo, exige-se a utilização dos receptores de dupla ou até mesmo tripla frequência, e antenas que possuem tecnologia capaz de mitigar consideravelmente os efeitos do multicaminhamento. Sob outra perspectiva, em serviços que não requeiram tanta precisão e acurácia, como por exemplo trabalhos relacionados aos SIGs, pode-se utilizar dispositivos mais baratos, de uma frequência. Além disso, até mesmo aparelhos muito mais acessíveis aos usuários, como é o caso de smartphones e tablets, poderão em um futuro próximo ser empregados neste tipo de serviço, já que a empresa Google liberou o acesso total às observáveis GNSS a partir de alguns dispositivos móveis com o sistema operacional Android Nougat (v. 7.0) ou mais recente (BANVILLE; VAN DIGGELEN, 2016; MALKOS, 2016). Com isto, é possível realizar o posicionamento de pontos com receptores de baixíssimo custo utilizando a fase da portadora e não somente a pseudodistância como era feito até então.

Apesar da perspectiva promissora de utilização de smartphones e tablets para determinadas atividades de Mensuração e Geodésia, é importante estar ciente de algumas limitações que estes aparelhos possuem, tais como: antena com baixa capacidade de supressão dos efeitos de multicaminhamento e alta sensibilidade; processo de *duty cycling* ativo (em quase todos os modelos); e osciladores TCXO de baixa qualidade e razoavelmente instáveis (BANVILLE; VAN DIGGELEN, 2016; HUMPHREYS et al., 2016).

3.5 MÉTODOS DE POSICIONAMENTO DE PONTOS

Existem muitas maneiras de se processar os dados e estabelecer as coordenadas de um ponto, sendo que nesta pesquisa são brevemente descritas apenas as utilizadas. Logo, destacam-se os métodos relativo estático e *Precise Point Positioning* (PPP). A não descrição dos outros

procedimentos não os caracterizam como de menor importância, sendo alguns deles até muito utilizados atualmente.

O leitor que tiver interesse em mais informações a respeito dos métodos de posicionamento com satélites artificiais poderá buscar detalhes em literaturas específicas, como aquelas citadas no início deste capítulo.

3.5.1 Processamento pelo método relativo estático

O posicionamento relativo estático consiste da aplicação de pelo menos dois receptores: um de referência, com coordenadas conhecidas (por exemplo, uma estação de uma rede de monitoramento contínuo, como a RBMC do IBGE, no Brasil); e um outro receptor (no mínimo), instalado no ponto onde se deseja conhecer as coordenadas. O vetor formado entre a antena de referência e a instalada no ponto a ser rastreado denomina-se linha base (SEGANTINE, 2005). A Figura 4 ilustra uma linha base formada entre as estações A e B.

Figura 4 - Vetor (linha base) entre duas estações

Fonte: Segantine (2005, p. 213).

Neste tipo de posicionamento, utiliza-se a fase da portadora em conjunto com a pseudodistância, tornando a técnica mais precisa. Ocorre então a necessidade de simultaneidade das observações, devendo existir pelo menos quatro satélites em comum visíveis em todas as estações do levantamento. As medições são então combinadas para obtenção de melhor

precisão da posição (SEGANTINE, 2005). Leick (2004) afirma que os erros comuns às estações são cancelados em razão da DD de fases, como é o caso dos efeitos da ionosfera e da troposfera que são eliminados quando os vetores são curtos. Outrossim, Hofmann-Wellenhof, Lichtenegger e Wasle (2008) diz que o tempo de observação necessário depende da extensão da linha base, do tipo do receptor quanto a capacidade de coletar uma ou duas frequências e da quantidade de satélites visíveis. Para vetores curtos (até 10 quilômetros), a acurácia pode atingir nível de milímetros.

3.5.2 Processamento pelo método PPP

No posicionamento pelo PPP, utilizam-se as fases das portadoras, bem como as pseudodistâncias obtidas através dos códigos C/A e P modulado. Além disso, empregam-se as efemérides precisas, correções dos relógios e atmosféricas, tendo como objetivo melhorar o ajuste do modelo. Para a solução de algumas incógnitas presentes no processamento por este método, como o atraso troposférico, os erros do relógio do receptor e a ambiguidade, são utilizadas várias ferramentas, como o ajuste sequencial pelo método dos mínimos quadrados e o filtro de Kalman estendido (HOFMANN-WELLENHOF; LICHTENEGGER; WASLE, 2008). Leick (2004) afirma que o método PPP garante acurácia de centímetros para um único receptor e levantamento estático de longa duração. Para posicionamento cinemático e adequada eliminação dos efeitos da ionosfera, a acurácia abaixo de dez centímetros é esperada.

4 REDES NEURAIS ARTIFICIAIS

Os estudos relacionados à RNAs tiveram suas origens na pesquisa de Warren McCulloch e Walter Pitts, de 1943, onde o primeiro modelo artificial de um neurônio foi apresentado. Desde o início, os trabalhos foram motivados pelo reconhecimento de que o cérebro humano realiza o processamento das informações de uma maneira totalmente diferente da computação convencional.

Nesta investigação, são apresentados os conceitos básicos para entender o que são RNAs e como elas funcionam, embasando as ideias e a metodologia proposta para solução do problema, devendo o leitor que tiver interesse em maiores informações consultar literaturas específicas, como Haykin (2008), Silva, Spatti e Flauzino (2010) e Goodfellow, Bengio e Courville (2016).

4.1 INSPIRAÇÃO BIOLÓGICA

O processamento de informações no cérebro humano acontece por meio de componentes biológicos operando em paralelo, sendo capaz de produzir pensamentos e aprender com as experiências. A célula fundamental deste órgão é o neurônio, o qual possui como tarefa conduzir os impulsos (estímulos elétricos produzidos por reações químicas). Enquanto o cérebro humano possui bilhões destas unidades e uma estrutura muito mais complexa, RNAs são constituídas de apenas centenas ou milhares de neurônios artificiais. Contudo, os eventos em circuitos computacionais ocorrem na ordem de nanossegundos, ou seja, em uma velocidade cinco a seis vezes maior do que no cérebro (HAYKIN, 2008; SILVA; SPATTI; FLAUZINO, 2010).

A Figura 5 expõe a representação de um neurônio piramidal (célula piramidal), um dos tipos mais comuns de neurônios corticais.

Figura 5 - Célula piramidal, ou neurônio piramidal

Fonte: Adaptado de Haykin (2008).

Um neurônio biológico é constituído, basicamente, por três partes principais: o Dendrito, responsável por adquirir os estímulos de outros neurônios ou do meio externo; Corpo celular, conhecido também como Soma, com a função de processar toda a informação recebida através dos Dendritos, e produzir um potencial de ativação que indica se a célula pode ou não gerar um impulso elétrico ao longo de seu Axônio, a terceira parte fundamental. Esta, é uma única extensão responsável por conduzir o estímulo elétrico para os outros neurônios.

As sinapses, ou terminações nervosas, são unidades estruturais elementares com função de intermediar a transmissão de impulsos elétricos de uma célula para outra, sem que haja o contato físico entre elas: a conexão entre os Axônios de um neurônio com os Dendritos de outro é feita por elementos neurotransmissores (HAYKIN, 2008).

A razão pela qual um potencial de ativação é utilizado para comunicação entre os neurônios, baseia-se na característica física dos Axônios: longos, com alta resistência elétrica e grande capacitância. Estudos mostram que a voltagem aplicada em uma das pontas do neurônio

cai exponencialmente com a distância, atingindo valores insignificantes na outra extremidade. Dessa maneira, o potencial de ativação evita a ocorrência de problemas na transmissão (HAYKIN, 2008; SILVA; SPATTI; FLAUZINO, 2010).

Ainda em relação à inspiração biológica de uma RNA, destaca-se o conceito de plasticidade cerebral: uma característica que permite a adaptação do sistema nervoso ao ambiente em seu entorno, criando novas conexões sinápticas ou reformulando as já existentes em função das necessidades, estímulos e experiências.

4.2 REDES NEURAIS ARTIFICIAIS E O NEURÔNIO ARTIFICIAL

RNAs podem ser entendidas como modelos computacionais compostos de unidades de processamento, conhecidos como neurônios artificiais, interconectados por sinapses artificiais (vetores e matrizes de pesos armazenadores do conhecimento adquirido). A ferramenta permite modelar a maneira como o cérebro realiza as tarefas e, devido à sua flexibilidade e alta capacidade de adaptação, possibilita a resolução de tarefas complexas de classificação, reconhecimento de padrões e regressão (HAYKIN, 2008; SILVA; SPATTI; FLAUZINO, 2010).

Empregando um conjunto suficiente de interconexões entre os neurônios artificiais, as redes podem atingir excelentes resultados nas tarefas que lhes são delegadas. Mas como funcionam os neurônios artificiais? Qual o papel destes dentro de um sistema complexo como uma RNA? O primeiro modelo de uma destas unidades foi proposto por McCulloch e Pitts (1943) e, posteriormente, aperfeiçoado no trabalho de Rosenblatt (1958), que apresentou o Perceptron, uma das mais simples arquiteturas de rede. Para entender a função de um neurônio artificial, é importante visualizar o esquema genérico apresentado na Figura 6.

Figura 6 - Modelo não linear de um neurônio artificial k

Fonte: adaptada de Haykin (2008).

O funcionamento de um neurônio artificial, denotado pela letra k , pode ser assim definido: os sinais (variáveis) de entrada da RNA (x_m), advindos de um ambiente externo, são multiplicados pelos seus respectivos pesos sinápticos (w_{km}). Em seguida, a somatória destas multiplicações, acrescida do termo bias (b_k), resulta no potencial de ativação (v_k), que passará pela função de ativação ($\varphi(\cdot)$) para determinação da saída (y_k). Os sinais de entrada geralmente são normalizados nos intervalos de 0 a 1 ou de -1 a 1. O termo *bias* exerce o papel de aumentar ou diminuir a entrada líquida da função de ativação, a qual limita a amplitude das saídas. Por fim, o potencial de ativação tem função de ativar ou não a unidade de processamento: quando este valor for positivo, o neurônio artificial produzirá um potencial excitatório; caso contrário, será inibitório.

4.2.1 Propriedades e Benefícios

Segundo Silva, Spatti e Flauzino (2010), entre as características mais importantes de uma RNA, podem-se destacar:

- Não linearidade do modelo;
- Capacidade de aprendizado e adaptação por experiência: modificação dos parâmetros (pesos sinápticos) de acordo com as entradas, ajustando a rede para o problema;

- Habilidade de generalização: produção de saídas satisfatórias quando da apresentação de entradas que nunca lhe tenham sido introduzidas anteriormente, estimando soluções desconhecidas até então;
- Tolerância a erros e falhas;
- Armazenamento distribuído: devido à grande quantidade de sinapses artificiais existentes dentro de uma RNA, todo o conhecimento obtido de determinado processo é armazenado de maneira compartilhada, permitindo incrementos na arquitetura perante algumas unidades que se tornaram inoperantes.

4.3 DEFINIÇÃO E CONCEITOS GERAIS

Existe uma diversidade enorme de funções de ativação, arquiteturas, topologias e processos de aprendizagem para uma RNA. A seguir, são apresentadas algumas informações básicas a respeito destes assuntos.

4.3.1 Funções de Ativação

Como já visto anteriormente, as unidades de processamento de uma RNA fazem uso de uma função de ativação que limita a amplitude de suas saídas. Existe uma variedade de tipos destas funções e, para Haykin (2008), Silva, Spatti e Flauzino (2010) e Géron (2017) podem-se destacar:

- a) Função Logística – limites de 0 e 1;

$$\varphi(v) = \frac{1}{1 + e^{-\beta \cdot v}} \quad (5)$$

Em que β é uma constante real associada ao nível de inclinação da função logística perante o seu ponto de inflexão.

b) Função Tangente Hiperbólica – limites de -1 e 1;

$$\varphi(v) = \frac{1 - e^{-\beta \cdot v}}{1 + e^{-\beta \cdot v}} \quad (6)$$

Em que β é uma constante real associada ao nível de inclinação da função tangente hiperbólica em relação ao seu ponto de inflexão.

c) Função Linear;

$$\varphi(v) = v \quad (7)$$

d) Função ReLU (*Rectified Linear Units*).

$$\varphi(v) = \begin{cases} v, & \text{se } v \geq 0 \\ 0, & \text{se } v < 0 \end{cases} \quad (8)$$

4.3.2 Arquitetura de uma Rede Neural Artificial

Uma RNA é formada, essencialmente, por três partes principais: camada de entrada, responsável pelo recebimento das informações oriundas do meio externo (variáveis, dados ou medições); camadas escondidas (ou intermediárias), compostas por neurônios artificiais com função de processar os dados e obter as características do processo; e camada de saída, designada para produzir e apresentar os resultados finais do modelo.

A arquitetura de uma RNA pode ser entendida como a maneira pela qual os seus inúmeros neurônios estão dispostos, uns em relação aos outros. A estruturação de uma rede neural está diretamente relacionada ao algoritmo de aprendizagem utilizado para treiná-la. Por outro lado, o conceito de topologia, considerando certo tipo de arquitetura, compreende as diferentes maneiras de composições estruturais possíveis de serem montadas, ou seja, a quantidade de neurônios artificiais, de camadas intermediárias e seus atributos (HAYKIN, 2008; SILVA; SPATTI; FLAUZINO, 2010).

Existem três classes fundamentais de arquiteturas: *Feedforward* de Camada Simples, *Feedforward* de Camadas Múltiplas e Arquitetura Recorrente (Realimentada).

De acordo com Haykin (2008), nas redes de arquitetura *Feedforward* de Camada Simples, não existem unidades escondidas, apenas uma camada de entrada e uma de saída, responsáveis pelo processamento das informações. Como o próprio nome diz, o fluxo de informações nesse tipo de rede é unidirecional, da camada de entrada até a de saída, e utiliza algoritmos de aprendizado baseados nas regras de Hebb e Delta.

Modelos mais complexos, como a arquitetura do tipo *Feedforward* de Camadas Múltiplas, possuem uma ou mais camadas intermediárias. Deseja-se que as unidades de processamento existentes nestas novas camadas intervenham entre as entradas e saídas do modelo, de modo a aprimorar os resultados. Assim, elas ficam responsáveis por extrair as particularidades das amostras e, conforme o aprendizado se desenvolve, vão descobrindo gradualmente as propriedades mais marcantes do sistema. Segundo Silva, Spatti e Flauzino (2010), a complexidade do problema a ser resolvido, a qualidade das informações disponíveis e também a precisão desejada para os resultados são fatores que, sobretudo, podem determinar o número de neurônios escondidos e a quantidade de camadas escondidas. Existem contradições na literatura a respeito da eficiência de se adicionar mais destas unidades no modelo, mas com os avanços computacionais, as RNAs mais profundas vem sendo implementadas com sucesso, resultando em soluções de maior eficácia em problemas complexos (BENGIO; LECUN, 2007; GOODFELLOW; BENGIO; COURVILLE, 2016).

É importante realçar que, tanto nas redes de arquitetura *Feedforward* de Camada Simples como nos modelos *Feedforward* de Camadas Múltiplas, a quantidade de neurônios na última camada sempre coincidirá com a quantidade de saídas desejadas para o processo.

A Figura 7 apresenta um exemplo de uma rede *Feedforward*, com duas camadas escondidas.

Figura 7 - Rede *Feedforward* de Camadas Múltiplas

Fonte: adaptada de Silva, Spatti e Flauzino (2010).

Dentre as RNAs de Camadas Múltiplas, pode-se realçar o modelo MLP, que durante muitos anos pesquisadores da área esforçaram-se para encontrar uma forma de treiná-lo. Somente com o trabalho de Rumelhart, Hinton e Williams (1986), introduzindo o algoritmo de treinamento *back-propagation*, isto foi possível. Atualmente, este tipo de rede é bastante popular e funciona muito bem para aproximação de funções, otimização de sistemas, reconhecimento de padrões e previsão de séries temporais, sendo treinado por algoritmos de aprendizado fundamentados na regra Delta generalizada e na regra Delta competitiva.

Finalmente, tem-se a arquitetura Recorrente, a qual realiza a realimentação dos neurônios, isto é, as saídas de determinadas unidades de processamento são realimentadas como sinais de entrada para outros neurônios, criando-se um *feedback loop*. Dessa maneira, o modelo é altamente indicado para previsão de séries temporais, otimização de sistemas e controle de processos, já que a característica de realimentação das unidades o qualifica como ideal para processamento dinâmico. Outrossim, tal propriedade faz com que este tipo de rede produza saídas baseando-se em valores anteriores e, portanto, determinados acontecimentos no passado irão persistir e interferir na geração de resultados futuros, criando uma espécie de memória. Redes Recorrentes são treinadas por algoritmos baseados na regra Delta generalizada e na minimização de funções de energia (HAYKIN, 2008; SILVA; SPATTI; FLAUZINO, 2010).

4.3.3 Processo de Aprendizagem

RNAs possuem a capacidade de aprender com base em amostras (padrões) que lhes são apresentadas, armazenando as informações mais importantes do comportamento do sistema em análise para, posteriormente, generalizar soluções. Entretanto, o processamento de treinamento da rede, obviamente, não se resume apenas na introdução de sinais de entrada, mas também na utilização de um algoritmo de aprendizado que, através de um conjunto de procedimentos bem organizados para adaptação dos pesos sinápticos e detecção de padrões nas amostras, consegue extrair as características do problema.

É comum a divisão do conjunto de amostras de treinamento de uma rede em dois subconjuntos: de treinamento e validação. O primeiro fica responsável por fornecer as informações à ferramenta para ajuste dos pesos, enquanto que o segundo possui amostras para validar o modelo, verificando sua capacidade de generalização. Normalmente, esta divisão ocorre na relação de 60 a 90% para o subconjunto de treinamento e 40 a 10% das amostras para o de validação.

Cada apresentação completa de amostras durante o processo de aprendizagem da rede é conhecida como época de treinamento. Pode-se optar por efetuar a modificação dos pesos sinápticos somente depois da exibição completa de um lote (*batch*) de amostras, denominando-se aprendizagem *off-line*; ou após a apresentação de cada observação, isto é, sem dividir o subconjunto de treinamento em *batches* (*on-line*) (HAYKIN, 2008).

Existem ainda algumas estratégias de como entrar com as informações no modelo, a saber: treinamento supervisionado, não supervisionado e com reforço. Conforme Silva, Spatti e Flauzino (2010), o primeiro tipo caracteriza-se pela apresentação à rede tanto dos sinais de entrada como das suas respectivas saídas desejadas. Dessa maneira, os pesos sinápticos serão ajustados comparando-os, de modo que as respostas da RNA sejam as mais próximas possíveis das verdadeiras.

No treinamento não supervisionado, por outro lado, não existem as saídas para as respectivas entradas, fazendo com que a própria ferramenta se organize em relação às características do problema e encontre subconjuntos similares, alterando os pesos sinápticos de maneira a refletir esta representação interna. Por fim, o treinamento com reforço pode ser considerado uma variação do supervisionado, também avaliando a diferença entre a saída do modelo e a desejada. No entanto, os ajustes dos pesos ocorrem em função de informações

qualitativas ou quantitativas do sistema, o que torna o processo realizado por tentativas e erros (SILVA; SPATTI; FLAUZINO, 2010).

4.4 *MULTILAYER PERCEPTRON* (MLP) – REDE PERCEPTRON DE MULTICAMADAS (PMC)

Nesta seção, são apresentadas as informações referentes ao modelo Perceptron de Multicamadas. É importante destacar que existem inúmeros tipos de RNAs, porém, como a metodologia deste trabalho baseia-se na utilização de MLPs, optou-se por descrever somente as suas características.

Como já visto anteriormente, a MLP é formada por uma camada de entrada, ao menos uma intermediária e uma de saída. Cada neurônio possui uma função de ativação e o sistema pode apresentar uma enorme quantidade de conexões. O método mais utilizado para treinamento de MLPs é o algoritmo *back-propagation*, conhecido também como regra Delta generalizada, e consiste de duas fases: primeiramente, ocorre a fixação dos pesos sinápticos do modelo e os sinais se propagam da camada de entrada até a de saída (*forward phase*). Em seguida, a resposta da ferramenta é comparada com a saída desejada, que também foi apresentada à rede previamente. A diferença entre elas é o erro, fundamental para o ajuste dos parâmetros. A segunda etapa (*backward phase*) consiste da propagação reversa do erro pela rede, isto é, da camada de saída a de entrada. Durante este processo, modificações são realizadas nos pesos sinápticos segundo uma regra de correção, de maneira a reduzir as discrepâncias e aproximar a resposta gerada com a desejada. Portanto, pode-se concluir que MLPs são redes de arquitetura *Feedforward* de Camadas Múltiplas e de treinamento supervisionado (HAYKIN, 2008).

Não é tratada nesta investigação a maneira pela qual os cálculos do algoritmo *back-propagation* são realizados. O leitor interessado neste assunto poderá buscar mais informações em Haykin (2008) e Silva; Spatti e Flauzino (2010).

4.4.1 Medida de desempenho e obtenção do melhor modelo

Uma das medidas de performance para avaliar um modelo de rede é o MSE, ou Erro Quadrático Médio. Este parâmetro de desempenho penaliza grandes erros e pode ser calculado de acordo com a Equação 9:

$$MSE = \frac{1}{N} \cdot \sum_{i=1}^N (d_i - y_i)^2 \quad (9)$$

Em que:

N : número de padrões (amostras) apresentados à RNA;

d_i : saída i desejada (valor verdadeiro);

y_i : saída i da rede.

Com o subconjunto de validação e uma medida de desempenho, é possível determinar o momento de interrupção do treinamento, de modo a evitar *underfitting* (capacidade insuficiente de extrair as propriedades do processo) e *overfitting* (memorização excessiva ao conjunto de treinamento, decorando as respostas) (HAYKIN, 2008; SILVA; SPATTI; FLAUZINO, 2010). Nas primeiras épocas de aprendizado, ocorrem grandes diminuições nos valores de erro e, posteriormente, observa-se uma estabilização. Em determinado instante, ocorre a inflexão na curva dos valores de MSE do subconjunto de validação, enquanto que a medida de desempenho das amostras de treinamento poderá continuar diminuindo. Este ponto de mínimo na curva de performance de validação é considerado o instante adequado para se interromper o treinamento da rede, já que a partir daí a capacidade de generalização do modelo poderá estar comprometida. É possível ainda optar pela implementação de uma técnica conhecida como *Early Stopping*, ou parada antecipada, para suspender o processo no instante em que o parâmetro de performance começa a aumentar ou quando não ocorrem mais melhorias significativas na medida de desempenho do subconjunto de validação (HAYKIN, 2008).

De acordo com Silva, Spatti e Flauzino (2010), é importante atentar-se aos pontos de mínimos locais, cujas ocorrências se dão em função da maneira pela qual os pesos sinápticos são inicializados. Estes locais podem indicar as melhores soluções para o conjunto de treinamento, mas possivelmente não representam o melhor modelo para generalização das

soluções. Neste caso, o processo de aprendizado direcionou a ferramenta para um ponto que não corresponde ao mais apropriado para a solução de entradas nunca apresentadas anteriormente. A Figura 8a expõe a situação de onde deve ocorrer a interrupção de treinamento da RNA (parada antecipada) e a Figura 8b apresenta a situação com mínimos locais e um mínimo global.

Figura 8 - a) Representação da época de parada do treinamento de acordo com o menor valor de MSE de validação; b) Esquema genérico de mínimos locais e global em função da inicialização dos pesos sinápticos (W) de um modelo

Fonte: Adaptado de Silva, Spatti e Flauzino (2010).

Finalmente, uma das dificuldades de aplicação das redes MLPs é a determinação da topologia mais adequada para a solução de dado problema, devido à enorme quantidade de configurações possíveis, tipo e características do algoritmo de aprendizado utilizado, da forma como os pesos são inicializados, da qualidade das amostras, dentre outros fatores. A técnica estatística de CV é bastante utilizada para isto. O objetivo é validar o modelo com base em conjuntos de dados não apresentados durante o treinamento. Contudo, ao longo dos testes, é importante que as amostras sejam divididas aleatoriamente em subconjuntos de treinamento e

validação repetidas vezes, dando possibilidade para que as redes candidatas experimentem informações diferentes em cada teste (SILVA; SPATTI; FLAUZINO, 2010).

5 METODOLOGIA

A proposta metodológica da presente investigação tem como objetivo principal estimar as observações da portadora L2 do sistema GPS com base nas observáveis da L1, obtidas tanto em receptores geodésicos como em dispositivos mais acessíveis, utilizando RNAs de múltiplas camadas escondidas. Optou-se por implementar a rede na biblioteca TensorFlow, por meio da linguagem Python. A seguir, as principais informações sobre o pacote estão apresentadas e os experimentos detalhados.

5.1 A BIBLIOTECA TENSORFLOW PARA *MACHINE LEARNING*

A linguagem Python, elaborada em 1991 por Guido van Rossumand, é considerada uma das mais eficientes e poderosas para programação. É robusta, multiplataforma e eficaz para desenvolvimento de algoritmos. Permite a instalação de bibliotecas e pacotes para funções específicas de forma gratuita (PYTHON, 2018). Nos últimos anos, está sendo empregada na programação de aplicativos, análise de dados em qualquer escala e ainda na elaboração de trabalhos relacionados à *machine learning*, sendo que esta última tarefa pode ser realizada por meio da biblioteca TensorFlow.

Criada por pesquisadores e engenheiros da Google, o TensorFlow oferece suporte para trabalhos de *Machine Learning* e *Deep Learning*, com núcleo de computação numérica flexível. O pacote possibilita a elaboração de tarefas complexas e de alta performance, com arquitetura que permite a computação em várias plataformas. Concebida inicialmente para aplicações de aprendizado de máquina, a ferramenta de estrutura *low level* atualmente está sendo empregada em diferentes ramos de atuação e por grandes empresas, como por exemplo a própria Google, a empresa de tecnologia Intel, a multinacional Coca-Cola, a rede social Twitter, a fabricante de aeronaves AIRBUS e a prestadora de serviços eletrônicos na área de transporte Uber, evidenciando a alta versatilidade, escalabilidade e qualidade do pacote (TENSORFLOW, 2018).

Basicamente, as tarefas de computação numérica dos modelos no TensorFlow acontecem dentro de ambientes, ou *Sessions*. Como o próprio nome sugere, a biblioteca trabalha com *tensors*, vetores ou matrizes de dados que fluem ao longo dos nós de um *Graph* (esquema,

grafo ou sistema), o qual geralmente é composto por dois elementos principais: os de operação e os que representam as unidades de dados (GÉRON, 2017; TENSORFLOW, 2018).

O TensorFlow admite que os modelos de RNAs possam ser altamente customizáveis, podendo-se testar inúmeros tipos de algoritmos de otimização, funções de ativação, técnicas de regularização e medidas de desempenho. As características e parâmetros da rede também podem ser ajustados, a saber: a forma como os pesos sinápticos são inicializados, a quantidade de neurônios nas camadas e o modelo matemático. Logo, é possível implementar uma RNA complexa de forma eficiente e amplamente ajustada à cada tipo de problema, visando obter o máximo de performance em todas as situações.

5.2 GERAÇÃO DAS OBSERVAÇÕES DA PORTADORA L2 POR MEIO DE RNAs

Decidiu-se por dividir esta etapa da investigação em duas partes principais. A primeira consistiu em selecionar o modelo adequado de RNA através do processo de CV, gerar as observações GPS da portadora L2 para quatro dias diferentes e comparar os resultados com os alcançados em outras pesquisas, validando o método com dados de algumas estações da RBMC, gerenciada pelo IBGE. A segunda fase estimou, com as configurações adotadas, as observáveis da portadora L2 a partir das observações da L1 coletadas em dispositivos de baixo custo, neste caso um smartphone Android, analisando a capacidade da ferramenta de aprimorar o posicionamento com aparelhos móveis e não somente as soluções oriundas de receptores profissionais de uma frequência. A contribuição desta etapa representa um importante avanço na aplicação de smartphones e tablets em algumas atividades de Geomática, como aquelas relacionadas aos SIGs.

É importante realçar que o método proposto de geração das observáveis da portadora L2 foi aplicado após a coleta dos dados da portadora L1, em ambas as etapas, isto é, não se realizou a estimativa destes valores em tempo real com a RNA no próprio receptor, e sim em um computador, após as missões de campo. Em adição, as soluções de posicionamento foram originadas com base no pós-processamento dos dados.

5.2.1 Parte 1 – Estimativa das observáveis da portadora L2 em estações RBMC

O primeiro passo para a elaboração desta etapa foi selecionar os dados para treinar e validar a RNA. As amostras devem possuir tanto as observações da portadora L1 como da L2 e os receptores de referência, fornecedores de todas as informações para o modelo, precisam estar próximos ao dispositivo de uma frequência, para que todas as observáveis experimentem praticamente os mesmos efeitos atmosféricos. Logo, o treinamento e a validação da RNA foram executados com observações GPS dos satélites rastreados nas estações RBMC de Inconfidentes/MG (MGIN), Piracicaba/SP (SPPI), Lins/SP (SPLI) e Jaboticabal/SP (SPJA), testando-se a rede nas observáveis da portadora L1 geradas no receptor instalado em São Carlos/SP (EESC). A Figura 9 expõe tal configuração, escolhida para comparar os resultados obtidos com os de trabalhos anteriores, de modo a avaliar o desempenho do novo modelo para exatamente os mesmos dados. Ademais, tem finalidade de garantir que a maioria dos satélites rastreados pelo dispositivo da EESC sejam observados por todas as outras estações.

Figura 9 - Disposição das estações RBMC utilizadas

Fonte: adaptada de Mazzetto (2017).

A seguir, a Tabela 3 exibe as datas e horários dos experimentos realizados nesta parte.

Tabela 3 - Data e horário dos testes com as estações RBMC

Teste	Data	Horário
1	15/09/2014	13:00 – 13:30
2	10/01/2015	14:30 – 15:00
3	10/06/2015	13:30 – 14:00
4	20/01/2016	15:00 – 15:30

Fonte: adaptada de Mazzetto (2017).

Para a extração das observáveis GPS dos arquivos das estações RBMC, foi aproveitado o programa RINEX ADAPTER desenvolvido na pesquisa de Mazzetto (2017). O software retira de arquivos RINEX selecionados as observações da fase da portadora, de acordo com a potência de sinal desejada, efetua a diferença dos valores entre épocas consecutivas e gera os arquivos com as amostras, prontos para serem inseridos na RNA. Na criação dos novos RINEX com as observáveis artificiais, o programa multiplica os valores da fase da portadora L1 na primeira época (de cada satélite) por um fator k , para determinar o número inicial da fase da portadora L2, pois o termo da ambiguidade é desconhecido. No entanto, neste trabalho estas observações foram zeradas, já que o processamento dos dados utiliza as diferenças destes valores entre épocas consecutivas para produzir as soluções de posicionamento. Quanto ao código, o software permite ao usuário selecionar uma das duas opções: extrair as amostras de maneira bruta ou pelo processo de truncagem inversa, o qual retira de cada observação apenas os 6 últimos algarismos. Mais informações de como o RINEX ADAPTER funciona podem ser encontradas em Mazzetto (2017).

A geração das observações da segunda portadora do sistema GPS deu-se de modo distinto para cada tipo de observável, em razão de que estas não se comportam da mesma forma ao longo do tempo e a fase da portadora é menos ruidosa em relação ao código. Por estes motivos, foram implementadas duas RNAs: uma que terá como sinal de entrada as diferenças de fases da portadora L1 e como saída as diferenças de fases da portadora L2; e outra tendo como entradas as observações do código C/A e como respostas as do código P2, utilizando o processo de truncagem inversa. Um método parecido de tratamento das observáveis GPS para RNAs foi utilizado em Leandro, Silva e Santos (2007).

Ressalta-se que durante esta etapa da investigação, foi determinada a topologia para cada RNA, a quantidade ideal de camadas escondidas e de neurônios, o algoritmo de otimização e outros parâmetros, objetivando-se utilizar as configurações geradoras dos melhores resultados. Todos os testes fizeram uso da metodologia de CV por amostragem aleatória, em inglês *Random Subsampling Cross-Validation*, onde o conjunto de dados disponível é subdividido aleatoriamente em subconjuntos de treinamento e validação cinco vezes ($CV = 5$), buscando-se analisar o desempenho de cada candidato perante dados sorteados de maneira distinta a cada experimento (SILVA; SPATTI; FLAUZINO, 2010).

Os novos arquivos RINEX, produzidos com as observáveis artificiais, foram processados no software Geo Office v. 5, da LEICA, disponível no Departamento de Engenharia de Transportes, da Escola de Engenharia de São Carlos, da Universidade de São Paulo, pelo método relativo para a estação EESC com as outras quatro como referências. As soluções de posicionamento foram avaliadas quanto à acurácia das coordenadas e comparadas com as produzidas em outros trabalhos, verificando se a RNA foi capaz de gerar as observações da portadora L2 de forma mais eficaz, validando assim o novo modelo. A Tabela 4 apresenta as coordenadas oficiais da estação EESC utilizadas para determinação da exatidão das soluções de posicionamento.

Tabela 4 - Coordenadas oficiais da estação RBMC de São Carlos (EESC)

Estação	Coordenada Geográfica (SIRGAS 2000)		Precisão (m)
EESC	Latitude	22 ° 00 ' 17,81599 " S	0,001
	Longitude	47 ° 53 ' 57,04968 " W	0,001
	Altitude Geométrica (m)	824,587	0,005

Fonte: IBGE (2018a).

As configurações básicas de processamento adotadas no programa Geo Office 5.0 nesta etapa são:

- Frequências L1 e L1+L2;
- Modelo troposférico de Hopfield;
- Modelo ionosférico Padrão (Standard) do LEICA Geo Office v. 5;
- Efemérides transmitidas;
- Máscara de elevação: 15°; e

- Apenas dados do sistema GPS.

5.2.2 Parte 2 – Geração das observáveis da portadora L2 em dispositivos móveis de baixo custo

Nesta etapa, um modelo de RNA já foi definido para cada tipo de observação. Trata-se então da implementação do método de estimação das observáveis GPS da portadora L2 para os dados obtidos em dispositivos de baixo custo, permitindo a utilização eficaz destes aparelhos em algumas atividades profissionais. A principal dificuldade neste momento foram as medições coletadas com smartphones e tablets, pois são mais ruidosas em comparação àquelas geradas nos receptores geodésicos das estações RBMC e, portanto, a RNA escolhida precisou ser capaz de tolerar os erros existentes nas entradas, aprendendo somente com as observáveis de maior qualidade.

Com um smartphone, rastream-se as observações da fase da portadora L1 em um ponto próximo à estação EESC da RBMC, em três dias e horários distintos com duração de trinta minutos cada. O local escolhido foi o marco 93670 em São Carlos/SP, da rede planialtimétrica SAT, mantida pelo IBGE. Outro teste foi realizado no ponto SAT 93509, localizado em Ribeirão Preto/SP, para demonstrar a capacidade do modelo até mesmo em locais distantes da estação que serviu como base para o seu treinamento. A Tabela 5 expõe as coordenadas geográficas destes marcos e suas distâncias em relação à EESC:

Tabela 5 - Coordenadas oficiais dos marcos SAT 93509 e 93670

Marco	Coordenada Geográfica (SIRGAS 2000)		Precisão (m)	Município
SAT 93509	Latitude	21 ° 12 ' 08,38994 " S	0,002	Ribeirão Preto/SP
	Longitude	47 ° 52 ' 04,67686 "W	0,004	
	Altitude Geométrica (m)	617,627	0,017	
	Distância aproximada em relação à EESC (km)	89	-	
SAT 93670	Latitude	21 ° 58 ' 54,13199 " S	0,002	São Carlos/SP
	Longitude	47 ° 52 ' 44,31879 "W	0,002	
	Altitude Geométrica (m)	848,914	0,019	
	Distância aproximada em relação à EESC (km)	3	-	

Fonte: IBGE (2018a).

A Tabela 6 apresenta as datas e horários em que foram realizadas as observações com o smartphone nos marcos SAT 93509 e SAT 93670.

Tabela 6 - Data e horário dos testes com o smartphone

Teste	Marco	Data	Horário
5	SAT 93670	12/12/2017	18:10 – 18:40
6	SAT 93670	24/09/2018	20:05 – 20:35
7	SAT 93670	25/09/2018	09:15 – 09:45
8	SAT 93509	08/12/2017	19:25 – 19:55

Fonte: elaborada pelo autor (2018).

A proximidade do marco SAT 93670 com a estação EESC é desejável, pois os experimentos utilizaram, para treinamento e validação da RNA, apenas os dados fornecidos pelo receptor geodésico instalado nesta estação. Dessa maneira, o modelo aprende somente com as observáveis geradas bem próximas ao ponto onde se deseja estimar as observações da portadora L2. Em contrapartida, o teste no marco de Ribeirão Preto/SP (SAT 93509) buscou identificar a capacidade da ferramenta de gerar as observáveis da portadora L2 em um ponto distante à estação fornecedora dos dados para treinamento e validação da RNA.

O aparelho móvel utilizado foi um smartphone Galaxy S8, fabricado pela empresa Samsung, disponível no mercado desde o ano de 2016 e equipado com o microrreceptor GNSS Broadcom BCM 4774IUB2G (MARKIT, 2017). Posicionou-se um painel de alumínio (30x30x0,6 cm) abaixo do aparelho para minimizar os efeitos do multicaminhamento de sinais (HUMPHREYS et al., 2016). A antena instalada no canto superior direito do smartphone (GALAXY S8 GUIDES, 2017) foi posicionada no centro do ponto a ser levantado e duas placas de madeira foram utilizadas como espaçadores entre o celular e o painel metálico, pois em alguns testes realizados anteriormente o contato direto com o alumínio prejudicou o recebimento dos sinais. Ademais, em experimentos preliminares o rastreamento do sinal obteve melhores resultados com a tela do aparelho voltada para baixo e por isso optou-se por esta configuração. A Figura 10 expõe a forma como o celular foi colocado sobre os marcos.

Figura 10 - Disposição do smartphone Galaxy S8 sobre o marco de concreto

Fonte: elaborada pelo autor (2018).

Os arquivos RINEX de uma frequência foram gerados no dispositivo móvel por meio do aplicativo Geo++ RINEX Logger (GEO++, 2016), disponível na Play Store da Google para aparelhos com o sistema operacional Android. A Figura 11 ilustra um exemplo de sua tela principal.

Figura 11 - Tela principal do aplicativo Geo++ RINEX Logger para Android

Fonte: elaborada pelo autor (2018).

Uma atualização para o programa RINEX ADAPTER foi elaborada em conjunto com o grupo de pesquisa da área de Geomática, para extração das observáveis GPS dos RINEX produzidos em smartphones e tablets, já que o software original não está preparado para receber arquivos deste tipo, pois apresentam algumas diferenças em relação aqueles criados pelas estações RBMC, como por exemplo: intervalo de rastreo menor (1 segundo) e ausência das observações da portadora L2. Com funcionamento bastante semelhante à versão anterior, a atualização recebeu o nome de “RINEX ADAPTER 2018”, possibilita ao usuário o tratamento dos dados da mesma forma que o programa RINEX ADAPTER aplicado em Mazzetto (2017), identifica e trabalha com as observações da portadora L5 e produz também arquivos de observação de dupla frequência a partir dos RINEX de simples frequência. A Figura 12 expõe a proposta de tela inicial da nova versão.

Figura 12 - Tela inicial do programa RINEX ADAPTER 2018

Fonte: elaborada pelo autor (2018).

Finalmente, com os dados tratados, geraram-se as observações da portadora L2 por meio das RNAs adotadas na primeira etapa desta pesquisa, e novos arquivos RINEX de dupla frequência para cada dia de teste foram criados. Para o processamento destes dados, o método PPP da solução on-line disponível no site do IBGE (IBGE, 2018b) foi utilizado e, mais uma vez, comparou-se todos os resultados originados dos arquivos de dupla frequência (com observações artificiais da portadora L2) com aqueles que utilizaram somente as observáveis da

L1, sendo a exatidão das coordenadas em relação às oficiais (Tabela 5) um parâmetro de avaliação.

5.2.3 – Fluxograma das etapas de elaboração da proposta

A seguir, a Figura 13 expõe as fases que constituem a metodologia deste trabalho, divididas de modo geral em duas partes principais destacadas na imagem pelas cores: azul para a primeira e verde para a segunda. É importante acentuar que todos os processamentos dos dados GPS, tanto na etapa 1 como na 2, foram realizados em um computador após a coleta das observáveis, não aplicando-se aqui métodos de posicionamento em tempo real.

Figura 13 - Fluxograma das etapas do método proposto

Fonte: elaborada pelo autor (2018).

6 RESULTADOS E DISCUSSÕES

Neste capítulo, primeiramente são apresentados os testes e resultados referentes à escolha das topologias de cada RNA, validadas perante o método de CV por amostragem aleatória com cinco sorteios de amostras. Na sequência, os tempos de treinamento e o MSE de validação de cada modelo estão expostos, de modo a se analisar o processo de aprendizagem da ferramenta em cada experimento. Por fim, os desvios planos e espaciais de cada solução de posicionamento utilizando as observações artificiais foram comparados com aqueles obtidos em outros trabalhos e com os arquivos de uma frequência.

6.1 IMPLEMENTAÇÃO E SELEÇÃO DAS RNAs

Diferentemente do que acontece em alguns programas, onde uma caixa de ferramentas específicas já contém as redes prontas, sendo possível alterar poucas configurações, a biblioteca TensorFlow oferece ao usuário a oportunidade de elaborar a sua RNA através de um código de programação, tornando o processo totalmente customizável. Assim, o passo inicial foi desenvolver o algoritmo genérico de uma rede, desde o carregamento e normalização dos sinais de entrada até a determinação da quantidade de camadas escondidas, neurônios e modelo matemático. Em um primeiro momento, implementou-se apenas a estrutura básica de uma MLP, a qual foi alterada e aperfeiçoada ao longo dos experimentos. Esta configuração genérica encontra-se no Apêndice A deste trabalho.

Sabe-se que a seleção da topologia ótima de uma RNA ocorre por meio de tentativas e erros e cada problema exigirá um modelo diferente. Com a estrutura básica de uma MLP, iniciaram-se os testes em relação à determinação da configuração mais adequada ao processo de geração das observações do código da portadora L2, usando-se para tanto as amostras de observações das estações RBMC (experimentos 1, 2, 3 e 4). A avaliação se deu pela busca de menores valores de MSE nos quatro primeiros testes, tanto para os subconjuntos de treinamento como para os valores de validação. Entretanto, nem sempre a rede escolhida generalizava os dados (estimava as observáveis da portadora L2 na estação EESC) de forma satisfatória em todos os arquivos de observação e, portanto, em determinados momentos foi necessário descartá-la ou modificá-la parcialmente, iniciando novamente as análises.

6.1.1 Modelo de RNA para a código da portadora

Inicialmente, testou-se a maneira de apresentar as observáveis do código à rede, isto é, se deveriam receber o processo de truncagem inversa ou não, e em quais intervalos os dados deveriam ser normalizados. Inserir as amostras brutas do código tornou o treinamento da RNA ineficaz, e em muitos casos a medida de desempenho não convergia para zero. Portanto, optou-se por realizar o processo de truncagem inversa. Para o intervalo de normalização, escolheram-se os limites entre 0 e 1, realizando-se este processo por meio da classe *MinMaxScaler*, fornecida pelo pacote Scikit-learn (SCIKIT-LEARN, 2018).

A restrição das entradas da rede em relação à potência do sinal (0, 5 e 7), como proposto com sucesso em Mazzetto (2017), foi aplicada na presente investigação. Entretanto, inserir todas as observações do código sem eliminar aquelas de menor qualidade se revelou a melhor opção neste instante, diferentemente da conclusão de Mazzetto (2017). Tal situação pode ser explicada pela capacidade de tolerância a ruídos existentes nos sinais de entrada que o novo modelo de RNA implementado desenvolveu. Outrossim, alguns experimentos foram conduzidos no sentido de determinar se a maior quantidade de dados poderia melhorar os resultados do treinamento e, conseqüentemente, a capacidade de generalização da rede. Adicionou-se mais uma estação RBMC, a de Botucatu/SP (SPBO), mas praticamente nada mudou.

No que concerne a quantidade de camadas escondidas e o número de neurônios, várias topologias foram averiguadas. A Figura 14 apresenta a média dos valores de MSE de validação para cada configuração testada, sorteando-se as amostras de treinamento e validação cinco vezes para o dia 20/01/2016. Apesar dos resultados serem de uma data somente, o processo de aprendizagem da RNA e os resultados obtidos em outros dias foram similares aos expostos na imagem abaixo.

Figura 14 - Comparação entre os modelos com diferentes quantidades de camadas escondidas e neurônios artificiais - Dia 20/01/2016 (15:00 – 15:30 h)

Fonte: elaborada pelo autor (2018).

Em preto (30), destaca-se a topologia escolhida em Silva (2003), aplicada em Mazzetto (2017), e em vermelho (18-8-7-5) a configuração escolhida nesta investigação. Observa-se que os valores de MSE de validação para a RNA com quatro camadas escondidas e 38 neurônios apresentou os melhores resultados e, portanto, foi adotada para geração das observáveis do código P2. Outros modelos testados também apresentaram resultados satisfatórios, enquanto que alguns produziam soluções absurdas ou não convergiam.

A Figura 15 expõe um experimento realizado para escolha da função de ativação da RNA. De acordo com a imagem, entre as duas funções de ativação analisadas, ReLU e Logística (SIGMOID), observa-se que a ReLU gerou valores mais baixos de MSE de validação e foi a adotada. Em algumas avaliações, ambas as funções se comportavam de maneira satisfatória, com a ReLU convergindo mais rapidamente. Géron (2017) afirma que na prática, esta função

geralmente produz excelentes saídas, é rápida no processamento e trabalha bem dentro de redes profundas.

Figura 15 - Comparação entre as funções de ativação - Dia 10/01/2015 (14:30 – 15:00 h)

Fonte: elaborada pelo autor (2018).

Para seleção dos algoritmos de otimização disponíveis na biblioteca TensorFlow, apenas os dois mais populares foram utilizados: o Adam e o Gradiente Descendente (SGD). Com base na Figura 16 (valores de MSE alcançados para o dia 15/09/2014), é possível verificar que o primeiro apresentou maior eficiência, convergindo rapidamente. Este resultado era esperado, pois Kingma e Ba (2014) já haviam demonstrado a eficácia do algoritmo em treinar MLPs, comparando-o com outros quatro. Contudo, é importante realçar: em alguns experimentos executados, o Gradiente Descendente atingiu performance tão boa quanto o Adam.

Figura 16 - Comparação entre os algoritmos de otimização - Dia 15/09/2014 (13:00 – 13:30 h)

Fonte: elaborada pelo autor (2018).

A maneira de como inicializar os pesos sinápticos em cada camada também foi testada, optando-se pelo tipo *Variance Scaling*, cujo objetivo é manter constante a escala da variância dos sinais de entrada até a camada final da rede. A Figura 17 apresenta os valores de MSE médio de validação para testes realizados no dia 10/06/2015. Embora alguns métodos de inicialização de pesos sinápticos também tenham atingido resultados satisfatórios, o *Variance Scaling* foi escolhido pois gerou melhores soluções de posicionamento.

Figura 17 - Comparação entre os métodos de inicialização de pesos sinápticos - Dia 10/06/2015 (13:00 – 13:30 h)

Fonte: elaborada pelo autor (2018).

Em relação ao processo de aprendizado da RNA, variou-se o tamanho dos *batches* e verificou-se que: utilizar lotes menores ou até mesmo o treinamento de modo *on-line* produziram as melhores saídas. A opção de não dividir as amostras em *batches* e ajustar os pesos após a apresentação de cada observação é indicada para sistemas de comportamento muito variável, com rápidas mudanças acontecendo a todo instante (SILVA; SPATTI; FLAUZINO, 2010). A grande quantidade de ruídos aleatórios nas observáveis do código provavelmente caracteriza esta situação e a hipótese pode ser corroborada com alguns testes referentes ao ano de 2016: neste período, o índice de atividade solar era mais baixo do que nos outros avaliados e, quando a RNA foi treinada, detectou-se a possibilidade de se aumentar o tamanho do *batch* de 1 para 10 amostras, sem prejudicar a performance da rede, indicando que as observações do sistema GPS eram de maior qualidade e o comportamento não variava tanto como o das outras de anos anteriores.

É importante realçar que os experimentos não foram realizados na mesma ordem aqui exposta, pois não devem seguir uma sequência uniforme. Estes precisam ser conduzidos de maneira interativa, a saber: em determinadas situações, mesmo com a quantidade de camadas e unidades de processamento já definida, a seleção do tipo de função de ativação, eventualmente, exigia alterações nestas configurações. Ademais, alguns métodos de inicialização dos pesos sinápticos produziam bons resultados com determinadas topologias, enquanto que com outras geravam valores absurdos. Em vista disso, existirão centenas, até milhares de possíveis combinações e, mesmo com uma extensa lista de candidatas, ainda podem haver modelos mais apropriados para a solução deste problema.

Resumindo, a configuração final adotada para a geração das observáveis do código P2 foi a seguinte:

- Normalização dos dados entre 0 e 1;
- Quatro camadas escondidas (18-8-7-5);
- Função de ativação = ReLU;
- Algoritmo de otimização = Adam;
- Inicialização dos pesos sinápticos pelo método de *Variance Scaling*;
- Tamanho do *batch* = 1 amostra por lote, exceto para o teste 4 (20/01/2016), no qual adotou-se o *batch* = 10 amostras por lote.

6.1.2 Modelo de RNA para a fase da portadora

Para a fase da portadora, novamente utilizando-se a classe *MinMaxScaler* da biblioteca Scikit-learn (SCIKIT-LEARN, 2018), normalizaram-se os dados entre os intervalos -1 e 1, reduzindo a propagação do erro, já que o fator de normalização é menor (LEANDRO; SILVA; SANTOS, 2007). Além disso, nesta etapa da pesquisa optou-se por restringir a potência do sinal (intensidade igual à 5), treinando a RNA somente com as observações de maior qualidade.

Os testes em relação à quantidade de camadas escondidas e neurônios limitaram-se em avaliar somente topologias de uma ou duas camadas intermediárias, pois acima disso verificou-se o processo de *overfitting* das amostras. A Figura 18 expõe os resultados obtidos para o quarto dia de teste (20/01/2016).

Figura 18 - Comparação entre os modelos com diferentes quantidades de camadas escondidas e neurônios artificiais - Dia 20/01/2016 (15:00 – 15:30 h)

Fonte: elaborada pelo autor (2018).

Em vermelho (8) destaca-se a topologia selecionada neste trabalho e em preto (6) a configuração adotada por Silva (2003) e utilizada em Mazzetto (2017). Analisando-se a imagem acima, constata-se que a RNA com 8 neurônios artificiais não foi a que apresentou os melhores valores de MSE. Entretanto, as topologias com maior quantidade de unidades de processamento memorizavam excessivamente o conjunto de treinamento, gerando soluções de posicionamento com as observáveis artificiais da segunda portadora piores do que aquelas que usavam somente as observações da L1. Por este motivo, optou-se pela rede com uma camada escondida e 8 neurônios. Em adição, realça-se mais uma vez que as avaliações para o dia 20/1/2016 (Figura 18) são representativas do comportamento da RNA para as outras datas analisadas neste trabalho.

No tocante às funções de ativação, dois tipos foram averiguados: Linear e Tangente Hiperbólica (TanH), sendo estas compatíveis com os intervalos de normalização. A Figura 19 apresenta os resultados obtidos.

Figura 19 - Comparação entre as funções de ativação - Dia 15/09/2014 (13:00 – 13:30 h)

Fonte: elaborada pelo autor (2018).

Com base nos experimentos realizados, constatou-se que a função TanH convergia mais rapidamente, produzindo também as melhores soluções de posicionamento e, por estes motivos, foi adotada para a RNA da fase da portadora.

Em relação aos algoritmos de otimização, novamente testaram-se o Adam e o SGD, sendo que o primeiro foi escolhido, pois forneceu os melhores resultados. A Figura 20 expõe

um dos testes realizados que corroboram a conclusão de que o Adam foi superior ao SGD em boa parte dos experimentos.

Figura 20 - Comparação entre os algoritmos de otimização - Dia 10/06/2015 (13:30 – 14:00 h)

Fonte: elaborada pelo autor (2018).

Finalmente, a última análise aferiu quais métodos de inicialização dos pesos sinápticos geram os menores valores de MSE de validação. De acordo com a Figura 21, observa-se que iniciar os pesos de forma aleatória e com distribuição uniforme, do inglês *Random Uniform*, gerou bons resultados. Outros modelos também apresentaram baixos MSE de validação, no entanto, estes degradavam as soluções de posicionamento. Logo, preferiu-se inicializar os pesos sinápticos pelo método *Random Uniform*.

Figura 21 - Comparação entre os métodos de inicialização de pesos sinápticos - Dia 10/01/2015 (14:30 – 15:00 h)

Fonte: elaborada pelo autor (2018).

O tamanho do *batch* para o processo de treinamento da fase da portadora ficou estabelecido em 128 amostras, sendo que um lote grande como este é possível graças à qualidade das observáveis, entre outros fatores. Resumindo, a configuração final da RNA para geração das observações da fase da portadora L2 é:

- Normalização dos dados entre -1 e 1;
- Uma camada escondida (8);
- Função de ativação = TanH;
- Algoritmo de otimização = Adam;
- Inicialização dos pesos sinápticos pelo método *Random Uniform*;
- Tamanho do *batch* = 128 amostras por lote.

6.2 TREINAMENTO E VALIDAÇÃO DAS RNAs

Com as configurações das redes e todos os parâmetros selecionados, geraram-se as observáveis da fase e do código da portadora L2 da estação EESC para os quatro dias. Basicamente, pode-se analisar o desempenho das RNAs por meio de seus valores de MSE do subconjunto de validação e do tempo de treinamento de cada uma.

6.2.1 Desempenho da RNA do código da portadora L2

A Tabela 7 expõe a performance das redes para todos os experimentos realizados com as observações do código.

Tabela 7 - MSE dos subconjuntos de validação e tempo de treinamento das RNAs do código

Teste	Local	Data	MSE do subconjunto de validação	Épocas de treinamento	Duração total (s)
1	EESC	15/09/2014	0,002882	2	18,58
2	EESC	10/01/2015	0,004782	2	14,07
3	EESC	10/06/2015	0,001514	5	88,98
4	EESC	20/01/2016	0,000095	2	03,89
5	SAT 93670	12/12/2017	0,004805	4	09,23
6	SAT 93670	24/09/2018	0,001416	5	10,53
7	SAT 93670	25/09/2018	0,009638	9	19,60
8	SAT 93509	08/12/2017	0,006827	6	15,53

Fonte: elaborada pelo autor (2018).

Verifica-se que o parâmetro de performance MSE apresentou valores muito baixos, próximos de zero, diferentemente do exposto em trabalhos anteriores (MAZZETTO, 2017) para os experimentos 1, 2, 3 e 4, onde estes números não ficaram nem mesmo abaixo da unidade e em quase todos os testes atingiram a casa da dezena. Em relação ao tempo de treinamento e a quantidade de épocas necessárias, mesmo com uma RNA de quatro camadas, o processo de aprendizagem foi relativamente rápido, de algumas dezenas de segundos e 9 iterações no máximo.

6.2.2 Performance da RNA da fase da portadora L2

No que concerne aos testes realizados com a fase da portadora, as RNAs apresentaram mais épocas de treinamento em função do tamanho do lote de amostras ser muito maior do que o utilizado para o código. Porém, de acordo com a Tabela 8, é possível observar que o tempo de aprendizagem dos modelos continuou baixo, de poucos segundos.

Tabela 8 - MSE dos subconjuntos de validação e tempo de treinamento das RNAs da fase

Teste	Local	Data	MSE do subconjunto de validação	Épocas de treinamento	Duração total (s)
1	EESC	15/09/2014	0,003958	367	18,19
2	EESC	10/01/2015	0,007323	217	15,21
3	EESC	10/06/2015	0,034828	83	02,79
4	EESC	20/01/2016	0,210098	21	01,06
5	SAT 93670	12/12/2017	0,010024	260	05,76
6	SAT 93670	24/09/2018	0,015376	321	06,45
7	SAT 93670	25/09/2018	0,011588	234	05,64
8	SAT 93509	08/12/2017	0,011301	275	06,18

Fonte: elaborada pelo autor (2018).

Em Mazzetto (2017), os MSE de validação alcançados são ligeiramente inferiores quando comparados aos obtidos nos experimentos 1, 2, 3 e 4 do presente trabalho. Isto se deu em função do processo de aprendizagem ter sido interrompido pelo *Early Stopping*, evitando o processo de *overfitting*. Identificou-se que continuar o treinamento das redes realmente melhoraria os valores de MSE de validação, contudo mantinha ou até mesmo degradava as soluções de posicionamento. Portanto, considerou-se cessar a aprendizagem da ferramenta após algumas épocas consecutivas não apresentarem mais reduções consideráveis no erro. Na seção de processamento dos dados GPS, uma comparação foi conduzida para investigar esta constatação.

6.2.3 Resumo dos processos de aprendizagem (tempo e épocas) das RNAs

A Tabela 9 apresenta a somatória total de épocas de treinamento das RNAs do código e da fase da portadora, bem como do tempo despendido para tanto. Estes valores sugerem uma estimativa de quantos segundos são necessários para o usuário, na prática, treinar e validar o modelo e gerar as observáveis da segunda portadora através da metodologia elaborada nesta pesquisa.

Tabela 9 - Somatória total do número de épocas de treinamento e tempo para geração das observáveis da portadora L2

Teste	Data	Épocas de treinamento	Duração total (s)
1	15/09/2014	369	36,77
2	10/01/2015	219	29,28
3	10/06/2015	88	91,77
4	20/01/2016	23	4,95
5	12/12/2017	264	14,99
6	24/09/2018	326	16,98
7	25/09/2018	243	25,24
8	08/12/2017	281	21,71

Fonte: elaborada pelo autor (2018).

Para os experimentos 1, 2, 3 e 4, o número de épocas de treinamento das RNAs, considerando ambos os modelos (para a fase e código da portadora), representa apenas 1,9% do número de iterações que foram realizadas na pesquisa de Mazzetto (2017) para os mesmos testes e dados, enquanto que o tempo total do processo equivale à somente 8,1%. Estes números apontam para a otimização do processo de geração das observações com RNAs, sendo extremamente rápido mesmo adotando-se modelos com mais de uma camada escondida.

6.3 PROCESSAMENTO DOS DADOS GPS

Como um dos objetivos da investigação é avaliar a possibilidade de se melhorar as soluções de posicionamento de pontos utilizando RNAs, não basta apenas analisar o desempenho dos modelos perante os valores de MSE de validação e tempo de treinamento. Em vista disso, este capítulo mostra os resultados referentes ao processamento dos dados GPS com as observáveis artificiais. Primeiramente, os desvios planos e espaciais das soluções obtidas pelo método relativo estático para a estação RBMC de São Carlos (EESC) serão apresentados e, em seguida, os valores do posicionamento com o método PPP nos marcos SAT 93509 e SAT 93670, onde utilizaram-se a antena e o microrreceptor GNSS instalados no smartphone Samsung Galaxy S8.

6.3.1 Processamento relativo para a estação de São Carlos (EESC da RBMC) – Etapa 1 da Metodologia

Aplicando as configurações descritas na seção 5 (Metodologia), processaram-se os dados GPS no software Leica Geo Office v. 5 e comparações dos desvios planos e espaciais foram realizadas entre soluções que utilizaram as seguintes observáveis:

- 1) L1 original dos arquivos RINEX da RBMC;
- 2) L1/L2modif obtidas em Mazzetto (2017); e
- 3) L1/L2a referentes aos dados gerados na presente investigação.

Estes paralelos visam comprovar a validade do método proposto, confrontando os resultados com aqueles considerados como padrão (L1 original) e outros alcançados em trabalhos anteriores (L1/L2modif). Isto posto, foi necessário determinar a acurácia das soluções em pontos com coordenadas conhecidas.

A Figura 22 expõe os desvios planos obtidos no processamento para o primeiro dia de teste, enquanto que a Figura 23 apresenta os desvios espaciais do mesmo experimento.

Figura 22 - Desvios planos do processamento relativo para o dia 15/09/2014 (Teste 1)

Fonte: elaborada pelo autor (2018).

Figura 23 - Desvios espaciais do processamento relativo para o dia 15/09/2014 (Teste 1)

Fonte: elaborada pelo autor (2018).

Para a data de 10/01/2015 (Teste 2), os desvios planos espaciais estão indicados nas Figuras 24 e 25, respectivamente.

Figura 24 - Desvios planos do processamento relativo para o dia 10/01/2015 (Teste 2)

Fonte: elaborada pelo autor (2018).

Figura 25 - Desvios espaciais do processamento relativo para o dia 10/01/2015 (Teste 2)

Fonte: elaborada pelo autor (2018).

A seguir, a Figura 26 apresenta os desvios planos obtidos no dia 10/06/2015 (Teste 3) e a Figura 27 mostra os desvios espaciais para o mesmo experimento.

Figura 26 - Desvios planos do processamento relativo para o dia 10/06/2015 (Teste 3)

Fonte: elaborada pelo autor (2018).

Figura 27 - Desvios espaciais do processamento relativo para o dia 10/06/2015 (Teste 3)

Fonte: elaborada pelo autor (2018).

Por fim, os desvios planos e espaciais dos processamentos realizados no dia 20/01/2016 (Teste 4) estão expostos nas Figuras 28 e 29, respectivamente.

Figura 28 - Desvios planos do processamento relativo para o dia 20/01/2016 (Teste 4)

Fonte: elaborada pelo autor (2018).

Figura 29 - Desvios espaciais do processamento relativo para o dia 20/01/2016 (Teste 4)

Fonte: elaborada pelo autor (2018).

Destaca-se nesta última imagem os desvios espaciais das linhas bases MGIN-EESC e SPPI-EESC. Aplicando as observáveis da portadora L2 geradas pelas RNAs, estes valores pioraram ou continuaram iguais, quando comparados aos obtidos utilizando somente as observações originais da primeira portadora. Uma análise com Box Plot revelou que o desvio espacial da componente vertical da linha base MGIN-EESC (do processamento L1/L2a) pode ser considerado um *outlier*, como mostra o losango em vermelho na Figura 30.

Figura 30 - Box Plot das coordenadas verticais

Fonte: elaborada pelo autor (2018)

Como as Figuras 22 à 29 demonstram, aplicando as observações da portadora L1 em conjunto com as da L2 geradas neste trabalho, foi possível diminuir os erros das soluções de posicionamento na maioria das vezes: a redução média foi de 43,9% para os desvios planos e 40,2% nos espaciais, quando comparados aos resultados obtidos com somente os dados originais da L1. Em vista disso, pode-se afirmar que o processo de estimação das observáveis da segunda portadora do sistema GPS por meio de RNAs é capaz de aprimorar o estabelecimento de pontos com o método relativo e utilizando dispositivos profissionais de uma frequência.

6.3.2 Influência da memorização excessiva (*overfitting*) durante o treinamento das RNAs no processamento dos dados GPS

Conforme descrito anteriormente, continuar o treinamento das RNAs da fase da portadora diminui o MSE de validação, como pode ser visto na Tabela 10. Porém, a Figura 31 apresenta um experimento realizado para o dia 15/09/2014 (13:00 – 13:30 h), mostrando que mesmo após quadruplicar a quantidade de iterações de aprendizagem, os resultados obtidos no

processamento dos dados no software LEICA Geo Office v. 5 permaneceram iguais ou pioraram, indicando que neste caso é totalmente ineficaz, ou desnecessário, treinar a rede por mais tempo. Avaliações para os outros dias sugerem a mesma situação.

Tabela 10 - Comparação dos valores de MSE de validação e tempo de treinamento da RNA da fase da portadora para diferentes quantidades de iterações – Dia 15/09/2014

Data	MSE do subconjunto de validação	Épocas de treinamento	Duração total (s)
15/09/2014	0,003958	367	18,19
	0,002041	734	34,71
	0,001083	1468	65,31

Fonte: elaborada pelo autor (2018).

Figura 31 - Comparação dos desvios espaciais para diferentes quantidades de épocas de treinamento da RNA da fase da portadora – Dia 15/09/2014

Fonte: elaborada pelo autor (2018).

Algumas linhas bases até melhoraram a acurácia das coordenadas após o aumento das épocas de treinamento da RNA. No entanto, a grande maioria se mantém igual ou piora, gerando soluções ruins. Assim, optou-se neste trabalho por aplicar a técnica de *Early Stopping*, visando reduzir os tempos de treinamento das redes, de modo a otimizar todo o processo de geração das observáveis da portadora L2 do sistema GPS, bem como mostrar que a maior quantidade de

épocas de aprendizagem resulta em avanços insignificantes ou na degradação do processamento dos dados.

6.3.3 Processamento PPP com smartphone Android (marcos SAT 93509 e 93670) – Etapa 2 da Metodologia

Nesta seção, serão apresentados os resultados dos processamentos realizados com a solução IBGE-PPP, a partir de arquivos produzidos pelo smartphone Samsung Galaxy S8. No total, foram 4 dias de teste em dias e horários distintos, buscando-se validar a metodologia em diferentes situações. Em determinados horários ensaiados, a ionosfera apresentava valores de TEC mais altos, enquanto que em outras a atividade era menor. Observa-se, porém, que em função da possibilidade de se superaquecer o smartphone durante períodos do dia de muito calor, realizaram-se as observações apenas no começo da manhã e final da tarde.

A seguir, as Figura 32 e 33 expõem os desvios planos e espaciais, respectivamente, obtidos para os quatro dias de testes com o smartphone. As barras mais claras referem-se aos erros de posicionamento aplicando-se apenas as observáveis da portadora L1, enquanto que as mais escuras representam os desvios das soluções perante a combinação das observações artificiais da portadora L2, geradas pela RNA, com as da L1.

Figura 32 - Desvios planos do processamento PPP para os quatro experimentos da segunda parte da metodologia (5, 6, 7 e 8)

Fonte: elaborada pelo autor (2018).

Figura 33 - Desvios espaciais do processamento PPP para os quatro experimentos da segunda parte da metodologia (5, 6, 7 e 8)

Fonte: elaborada pelo autor (2018).

É importante acentuar que todos os experimentos realizados apresentaram melhor acurácia quando da utilização das observações artificiais da portadora L2, geradas pela RNA,

em conjunto com as da L1. Em média, os desvios planos e espaciais foram reduzidos em, aproximadamente, 49,1% e 48,4%, respectivamente, indicando que a proposta do trabalho foi eficaz no que concerne ao aprimoramento das soluções de posicionamento com o método PPP, utilizando dispositivos móveis de baixo custo.

7 CONSIDERAÇÕES FINAIS

Este trabalho aplicou RNAs para estimar as observações da portadora L2 do sistema GPS, objetivando aprimorar o pós-processamento dos dados, bem como eliminar a necessidade de utilização de um receptor de dupla frequência em algumas situações. Para tanto, fez uso de uma nova abordagem, avaliou diversas topologias, de modo a adotar a configuração de rede mais adequada para gerar cada observável GPS. Executando testes com dados coletados em receptores geodésicos, das estações RBMC, e também obtidos em um dispositivo de menor qualidade (microrreceptor instalado em um smartphone Samsung Galaxy S8), apurou-se a capacidade do método em prever as observações da portadora L2 em duas categorias diferentes de aparelhos.

A facilidade de implementação das RNAs e a possibilidade de adaptá-las completamente ao problema podem ser consideradas algumas das principais vantagens da biblioteca TensorFlow. O pacote permitiu ao autor analisar uma grande quantidade de candidatos pelo método de CV por amostragem aleatória, e identificar quais RNAs apresentaram os melhores resultados. Concisamente, as MLPs selecionadas nesta pesquisa possuem até 4 camadas escondidas e 38 unidades de processamento, diferente do que foi proposto em investigações anteriores, onde modelos com somente uma camada intermediária foram adotados. Em adição, empregar o algoritmo de aprendizagem Adam e a função de ativação ReLU foi uma das características centrais que otimizou a geração das observáveis da segunda portadora do sistema GPS.

No tocante à restrição dos dados de acordo com a potência do sinal, Mazzetto (2017) concluiu que aplicar esta metodologia permitiu remover grande parte dos ruídos existentes nas amostras de entrada e, conseqüentemente, melhorar as soluções de posicionamento. Nesta pesquisa, o procedimento foi adotado de forma parcial: para o código da portadora, revelou-se que restringir as observações sob este critério diminuía a capacidade de generalização da RNA. Contudo, para a fase foi necessário selecionar as observáveis com potência do sinal maior ou igual à 5. Tal constatação baseia-se na hipótese de que a rede do código da portadora (4 camadas escondidas) foi capaz de tolerar os erros existentes nas amostras mais ruidosas. Além disso, aumentar ainda mais os limites em relação à potência do sinal tornavam os dados não representativos do fenômeno.

Quanto ao treinamento e validação das RNAs, pode-se concluir que foi extremamente rápido, de poucos segundos e representando menos de 10% do tempo gasto em outros trabalhos (para os testes 1, 2, 3 e 4). O número de iterações para completar o processo também foi bastante pequeno, sempre menor que 370 épocas. Em relação aos valores de MSE de validação dos modelos aplicados para o código e fase da portadora, todos ficaram muito próximos de zero e nem mesmo os piores resultados atingiram a unidade, revelando bom desempenho das redes em todas as avaliações.

Outro ponto a ser destacado é a influência da memorização excessiva, ou *overfitting*, no processamento final dos dados GPS. Detectou-se que interromper o treinamento das RNAs após algumas épocas sem melhorias significativas (*Early Stopping*) produzia as melhores soluções de posicionamento, como já esperado de acordo com a revisão da literatura. Proceder a aprendizagem da rede após determinado instante revelou que a acurácia dos resultados (desvios planos e espaciais) se mantinha praticamente igual ou até mesmo era degradada. Dessa maneira, apenas poucos segundos de treinamento para ambos os tipos de observáveis foram necessários para se obter valores coerentes.

No que concerne ao estabelecimento de pontos com o método relativo, este trabalho teve como objetivo melhorar a qualidade do posicionamento por meio da geração das observações da portadora L2. Logo, não bastava apenas produzir as observáveis, mas também criar novos arquivos RINEX de dupla frequência com elas e averiguar a acurácia das soluções, de modo a validar a metodologia. Aplicando as observações estimadas pelas RNAs em conjunto com as originais da primeira portadora, detectou-se, na grande maioria das linhas bases, reduções significativas em seus desvios planos e espaciais (aproximadamente 40%) quando comparados aos obtidos com apenas as observáveis da L1. Ademais, alguns vetores apresentaram erros menores do que foi exposto em Mazzetto (2017) e outros atenderam à norma de georreferenciamento de imóveis rurais, do INCRA, a qual determina desvio plano inferior à 50 cm. Entretanto, deve-se realçar que não foi possível aplicar a combinação L3 (*iono-free*) no processamento relativo dos arquivos RINEX de dupla frequência produzidos nesta investigação (na primeira parte da proposta), similarmente ao que foi evidenciado em pesquisas anteriores.

Para a segunda etapa da metodologia, foi necessária a elaboração de um novo programa para tratamento dos dados oriundos de dispositivos móveis Android. Esta atualização recebeu o nome de RINEX ADAPTER 2018, possui novas funções para tratamento das amostras e já utiliza as observáveis da portadora L5. Além disso, o software recebeu melhorias em seu sistema de adição de arquivos e permite agora configurar quais serão os valores da fase da

portadora L1, podendo-se escolher entre manter os dados originais ou alterá-los. Este novo programa possibilitou a criação dos arquivos RINEX de dupla frequência, a partir dos gerados no smartphone com apenas as observações da portadora L1.

Ainda em relação à segunda parte da proposta, optou-se por realizar o processamento utilizando o método PPP, através da solução on-line do IBGE (IBGE-PPP). Pela primeira vez, de acordo com a revisão bibliográfica, foi possível combinar as observáveis artificiais da portadora L2, produzidas pelas RNAs, com as originais da L1, de modo a se obter a portadora L3 (*iono-free*) em todos os experimentos da segunda etapa da metodologia, reduzindo consideravelmente os efeitos da ionosfera. Esta asserção pode ser verificada no campo “Frequência processada” dos relatórios de processamento fornecidos pelo IBGE (Anexo B).

Finalmente, a conjectura de que seria possível melhorar as soluções de posicionamento com smartphones Android por meio da utilização de RNAs foi confirmada com os testes 5, 6, 7 e 8, pois todas as soluções de posicionamento apresentaram melhoras significativas na acurácia de suas coordenadas. A redução dos desvios planos e espaciais da ordem de 50% representa um cenário de importante avanço para a aplicação desses aparelhos em determinadas atividades profissionais de geodésia: em um dos experimentos com o dispositivo móvel (teste 7-SC), foi possível até mesmo atender a normativa do INCRA (desvio plano inferior à 50 cm).

Portanto, conclui-se que o método proposto pode ser usado não somente com observações GPS de boa qualidade (conforme as amostras utilizadas por Mazzetto (2017)) e oriundas de receptores topográficos ou geodésicos, mas também com observáveis coletadas com aparelhos móveis de baixo custo, que possuem hardware GNSS de qualidade inferior e com severas limitações. Os resultados obtidos a partir destes dados, indicam esta metodologia para aplicações em SIG, as quais apresentam requisitos de acurácia no posicionamento com satélites menos restritivos em relação às condições exigidas nos trabalhos geodésicos.

7.1 SUGESTÕES PARA TRABALHOS FUTUROS

Primeiramente, sugere-se para próximas pesquisas aumentar o número de testes utilizando o smartphone, na busca de uma amostragem estatisticamente mais confiável de resultados em função da maior quantidade de dados e experimentos. Neste trabalho, mostrou-se que é possível aplicar o método em aparelhos de baixo custo financeiro, entretanto em função

do tempo exigido para realização das sessões de observações, geração das observáveis da portadora L2 e liberação das efemérides precisas para aplicação do PPP, decidiu-se por limitar o número de testes com o smartphone em quatro dias. Outra proposta é a utilização de algoritmos genéticos na busca de uma configuração de RNA ainda melhor para o problema, pois estes conseguem analisar uma vasta quantidade de candidatos em um período de tempo muito menor do que um ser humano precisaria. Esta técnica inicia o processo de otimização com apenas um modelo, o qual é manipulado ao longo dos experimentos para determinação de uma solução ótima. Assim, é possível que se encontre uma RNA mais adequada ao processo de geração das observações da portadora L2, uma vez que o número de possibilidades é muito grande.

Em adição, propõem-se a aplicação de uma RNA para cada satélite rastreado, uma vez que o fenômeno de geração das observáveis pode ser considerado local, isto é, cada veículo observado encontra-se em um ponto do espaço e o sinal emitido por este atravessa as camadas da Ionosfera e Troposfera em uma região com características e comportamento distintos de qualquer outra. Assim, pode-se afirmar que cada satélite experimenta um dado efeito atmosférico e, portanto, a hipótese consiste em gerar as observações separadamente, para que a RNA aprenda o comportamento do sinal de cada veículo de maneira mais eficiente, reproduzindo-o também com maior precisão no momento da geração dos dados, pois o processo acontecerá individualmente, ao invés de treinar e validar o modelo misturando as observáveis de todos os satélites.

Analisar se o método proposto neste trabalho é capaz também de estimar as observáveis da portadora L5, podendo-se obter arquivos RINEX de observação de tripla frequência, é outra sugestão para próximas pesquisas. Por fim, a criação de um aplicativo para smartphones e tablets que consiga produzir os dados em tempo real recebe destaque como proposta de uma futura investigação, pois isto permitiria melhorar o posicionamento com smartphones e tablets de forma instantânea, não tendo o usuário a necessidade de conhecer o processo de forma profunda, nem de enviar os arquivos para um servidor, ou computador, para o pós-processamento dos dados.

REFERÊNCIAS

- ABNT. **ABNT - Associação Brasileira de Normas Técnicas**. Disponível em: <<http://www.abnt.org.br/>>. Acesso em: 26 abr. 2018.
- ALTINAY, O.; TULUNAY, E.; TULUNAY, Y. Forecasting of ionospheric frequency using neural networks. **Geophysical Research Letters**, v. 24, n. 12, p. 1467–1470, 1997.
- BANVILLE, S.; VAN DIGGELEN, F. Precise GNSS for Everyone: Precise Positioning Using Raw GPS Measurements from Android Smartphones. **GPS World**, v. 27, n. November, p. 43–48, 2016.
- BENGIO, Y.; LECUN, Y. Scaling Learning Algorithms towards AI. **Large Scale Kernel Machines**, n. 1, p. 321–360, 2007.
- CANDER, L. R. et al. Ionospheric forecasting technique by artificial neural network. **Electronics Letters Online**, v. 34, n. 16, p. 1573–1574, 1998.
- CHEN, X. et al. Novel hybrid of strong tracking Kalman filter and wavelet neural network for GPS/INS during GPS outages. **Measurement**, v. 46, n. 10, p. 3847–3854, 2013.
- DABOVE, P.; DI PIETRA, V. Towards high accuracy GNSS real-time positioning with smartphones. **Advances in Space Research**, 2018.
- EMARKETER. **Mobile Phone, Smartphone Usage Varies Globally**. Disponível em: <<https://www.emarketer.com/Article/Mobile-Phone-Smartphone-Usage-Varies-Globally/1014738>>. Acesso em: 20 maio. 2018.
- FERREIRA, A. A. et al. Short-term estimation of GNSS TEC using a neural network model in Brazil. **Advances in Space Research**, v. 60, n. 8, p. 1765–1776, 2017.
- GALAXY S8 GUIDES. **Galaxy S8 layout and Galaxy S8+ layout**. Disponível em: <<http://gadgetguideonline.com/s8/galaxy-s8-layout-and-galaxy-s8-layout/>>. Acesso em: 8 jan. 2018.
- GEO++. **Logging of GNSS Raw Data on Android | Geo++**. Disponível em: <<http://www.geopp.de/logging-of-gnss-raw-data-on-android/>>. Acesso em: 4 jan. 2018.
- GÉRON, A. **Hands-On Machine Learning with Scikit-Learn and TensorFlow**. 1. ed. Sebastopol: O'Reilly Media, 2017.
- GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. **Deep learning (adaptive computation and machine learning series)**. Cambridge: MIT Press, 2016.

HABARULEMA, J. B.; MCKINNELL, L.-A.; CILLIERS, P. J. Prediction of global positioning system total electron content using Neural Networks over South Africa. **Journal of Atmospheric and Solar-Terrestrial Physics**, v. 69, n. 15, p. 1842–1850, 2007.

HAGAN, M. T.; MENHAJ, M. B. Training Feedforward networks with the Marquardt algorithm. **IEEE Transactions on Neural Networks**, v. 5, n. 6, p. 989–993, 1994.

HATANAKA, Y. A Compression Format and Tools for GNSS Observation Data. **Bulletin of the Geographical Survey Institute**, v. 55, p. 21–30, 2008.

HAYKIN, S. **Neural Networks and Learning Machines**. 3. ed. Upper Saddle River: Pearson Prentice Hall, 2008.

HEBB, D. O. **The organization of behavior: a Neuropsychological theory**. New York: John Wiley & Sons, 1949.

HERNÁNDEZ-PAJARES, M.; JUAN, J. M.; SANZ, J. Neural network modeling of the ionospheric electron content at global scale using GPS data. **Radio Science**, v. 32, n. 3, p. 1081–1089, 1997.

HINTON, G. E. et al. Improving neural networks by preventing co-adaptation of feature detectors. **arXiv preprint arXiv:1207.0580**, p. 1–18, 2012.

HOFMANN-WELLENHOF, B.; LICHTENEGGER, H.; WASLE, E. **GNSS - Global Navigation Satellite Systems**. 6. ed. New York: SpringerWien, 2008.

HOPFIELD, J. J. Neural networks and physical systems with emergent collective computational abilities. **Proceedings of the National Academy of Sciences**, v. 79, n. 8, p. 2554–2558, 1982.

HORNIK, K.; STINCHCOMBE, M.; WHITE, H. Multilayer Feedforward networks are universal approximators. **Neural Networks**, v. 2, n. 5, p. 359–366, 1989.

HUMPHREYS, T. E. et al. On the feasibility of cm-accurate positioning via a smartphone's antenna and GNSS chip. **Proceedings of the IEEE/ION Position, Location and Navigation Symposium, PLANS 2016**, p. 232–242, 2016.

IBGE. **IBGE | Portal do IBGE**. Disponível em: <<https://www.ibge.gov.br/index.php>>. Acesso em: 16 maio. 2018a.

IBGE. **IBGE-PPP**. Disponível em: <<https://www.ibge.gov.br/geociencias-novoportal/informacoes-sobre-posicionamento-geodesico/servicos-para-posicionamento-geodesico/16334-servico-online-para-pos-processamento-de-dados-gnss-ibge-ppp.html?=&t=o-que-e>>. Acesso em: 8 out. 2018b.

INDRIYATMOKO, A. et al. Artificial neural networks for predicting DGPS carrier phase and pseudorange correction. **GPS Solutions**, v. 12, n. 4, p. 237–247, 2008.

JONES, T. W.; MARZEN, L.; CHAPPELKA, A. Horizontal Accuracy Assessment of Global Positioning System Data from Common Smartphones. **Papers in Applied Geography**, v. 1, n. 1, p. 59–64, 2015.

JWO, D. J.; CHIN, K. P. Applying Back-propagation neural networks to GDOP approximation. **The Journal of Navigation**, v. 55, n. 1, p. 97–108, 2002.

JWO, D. J.; LAI, C. C. Neural network-based GPS GDOP approximation and classification. **GPS Solutions**, v. 11, n. 1, p. 51–60, 2007.

KAVZOGLU, T.; SAKA, M. H. Modelling local GPS/levelling geoid undulations using artificial neural networks. **Journal of Geodesy**, v. 78, n. 9, p. 520–527, 2005.

KINGMA, D. P.; BA, J. L. Adam: a method for Stochastic optimization. **International Conference on Learning Representations**, p. 1–15, 2014.

LEANDRO, R. F.; SANTOS, M. C. A neural network approach for regional vertical total electron content modelling. **Studia Geophysica et Geodaetica**, v. 51, n. 2, p. 279–292, 2007.

LEANDRO, R. F.; SILVA, C. A. U.; SANTOS, M. C. Feeding neural network models with GPS observations: a challenging task. **Dynamic Planet**, p. 186–193, 2007.

LEICK, A. **GPS Satellite Surveying**. 3. ed. Hoboken: JohnWiley & Sons, 2004.

LEICK, A.; RAPOPORT, L.; TATARNIKOV, D. **GPS Satellite Surveying**. 4. ed. Hoboken: JohnWiley & Sons, 2015.

LIU, J. et al. Performance assessment of GNSS measurements from Android platform. **Proceedings of 6th International Conference on Computer Science and Network Technology (ICCSNT)**, p. 472–476, 2017.

MA, X. F. et al. Three-dimensional ionospheric tomography using observation data of GPS ground receivers and ionosonde by neural network. **Journal of Geophysical Research: Space Physics**, v. 110, n. A5, p. 1–12, 2005.

MALKOS, S. **Google to provide raw GNSS measurements : GPS World**. Disponível em: <<http://gpsworld.com/google-to-provide-raw-gnss-measurements/>>. Acesso em: 4 jan. 2018.

MARKIT, I. **Samsung Galaxy S8 (SM-G950N) Preliminary BOM Estimates - Top Cost Driver Report**, 2017.

MAZZETTO, J. V. B. **Estimação das observáveis L2 do sistema GPS, através do uso de Redes Neurais Artificiais**. São Carlos: Escola de Engenharia de São Carlos da Universidade de São Paulo (USP), 2017.

MCCULLOCH, W. S.; PITTS, W. A logical calculus of the ideas immanent in nervous activity. **The Bulletin of Mathematical Biophysics**, v. 5, n. 4, p. 115–133, 1943.

MINSKY, M. L.; PAPERT, S. A. **Perceptrons: an introduction to computational geometry**. Cambridge: MIT Press, 1969.

MONICO, J. F. G. **Posicionamento pelo GNSS**. 2. ed. São Paulo: Editora UNESP, 2008.

MOSAVI, M. R. A Wavelet Based Neural Network for DGPS corrections prediction. **WSEAS Transactions on Systems**, v. 3, n. 10, p. 3070–3075, 2004.

MOSAVI, M. R. A practical approach for accurate positioning with L1 GPS receivers using neural networks. **Journal of Intelligent & Fuzzy Systems: Applications in Engineering and Technology**, v. 17, n. 2, p. 159–171, 2006.

MOSAVI, M. R. GPS receivers timing data processing using Neural Networks: optimal estimation and errors modeling. **International Journal of Neural Systems**, v. 17, n. 5, p. 383–393, 2007.

NATIONAL COORDINATION OFFICE FOR SPACE-BASED POSITIONING NAVIGATION AND TIMING. **GPS Space Segment**. Disponível em: <<https://www.gps.gov/systems/gps/space/#generations>>. Acesso em: 10 maio. 2018.

PETOVELLO, M. What are the actual performances of GNSS positioning using smartphone technology? **Inside GNSS**, v. 9, n. 6, p. 34–37, 2014.

PYTHON. **Welcome to Python.org**. Disponível em: <<https://www.python.org/>>. Acesso em: 16 maio. 2018.

RAPIŃSKI, J.; TOMASZEWSKI, D.; KOWALSKI, M. Analysis of the code and carrier phase measurements performed with LEA-6T GPS receiver. **The 9th International Conference “ENVIRONMENTAL ENGINEERING”**, v. 9, p. 1–7, 2014.

REALINI, E. et al. Precise GNSS Positioning Using Smart Devices. **Sensors**, v. 17, n. 11, p. 2434–2448, 2017.

REINKE, M. et al. Determinação da superfície geoidal através de Redes Neurais Artificiais. **Gaea-Journal of Geoscience**, v. 3, n. 1, p. 27–36, 2007.

ROSENBLATT, F. The perceptron: A probabilistic model for information storage and organization in **Psychological Review**, v. 65, n. 6, p. 386–408, 1958.

RUMELHART, D. E.; HINTON, G. E.; WILLIAMS, R. J. Learning representations by Back-propagating errors. **Nature**, v. 323, n. 6088, p. 533–536, 1986.

SANG, J.; KUBIK, K.; ZHANG, L. **Prediction of DGPS Corrections with Neural Networks**. Knowledge-Based Intelligent Electronic Systems, 1997. KES'97. Proceedings., 1997 First International Conference on. **Anais...IEEE**, 1997

SCHAEFER, M.; WOODYER, T. Assessing absolute and relative accuracy of recreation-grade and mobile phone GNSS devices: a method for informing device choice. **Area**, v. 47, n. 2, p. 185–196, 2015.

SCIKIT-LEARN. **Scikit-learn: Machine Learning in Python**. Disponível em: <<http://scikit-learn.org/>>. Acesso em: 25 out. 2018.

SEGANTINE, P. C. L. **GPS: Sistema de Posicionamento Global**. São Carlos: EESC/USP, 2005.

SEMENIUK, L.; NOURELDIN, A. Bridging GPS outages using neural network estimates of INS position and velocity errors. **Measurement Science and Technology**, v. 17, n. 10, p. 2783–2798, 2006.

SILVA, I. N.; SPATTI, D. H.; FLAUZINO, R. A. **Redes Neurais Artificiais para Engenharia e Ciências aplicadas**. 2. ed. São Paulo: Artliber, 2010.

SILVA, I.; SEGANTINE, P. C. L. **Topografia para Engenharia - Teoria e prática de Geomática**. 1. ed. Rio de Janeiro: Elsevier, 2015.

SILVA, C. A. U. DA. **Um método para estimar observáveis GPS usando redes neurais artificiais**. São Carlos: Escola de Engenharia de São Carlos da Universidade de São Paulo (USP), 2003.

SRIVASTAVA, N. et al. Dropout: a simple way to prevent neural networks from overfitting. **Journal of Machine Learning Research**, v. 15, p. 1929–1958, 2014.

TENSORFLOW. **TensorFlow**. Disponível em: <<https://www.tensorflow.org/>>. Acesso em: 16 maio. 2018.

TULUNAY, E. et al. Forecasting total electron content maps by neural network technique. **Radio Science**, v. 41, n. 4, p. 1–12, 2006.

VERONEZ, M. R. et al. Regional mapping of the geoid using GNSS (GPS) measurements and an Artificial Neural Network. **Remote Sensing**, v. 3, n. 4, p. 668–683, 2011.

WIDROW, B.; HOFF, M. E. Adaptive switching circuits. **Neurocomputing: foundations of research**, p. 123–134, 1960.

WILLISCROFT, L. A.; POOLE, A. W. V. Neural networks, foF2, sunspot number and magnetic activity. **Geophysical Research Letters**, v. 23, n. 24, p. 3659–3662, 1996.

WINTOFT, P.; CANDER, L. R. Twenty-four hour predictions of foF2 using time delay neural networks. **Radio Science**, v. 35, n. 2, p. 395–408, 2000.

ZANDBERGEN, P. A. Accuracy of iPhone locations: A comparison of assisted GPS, WiFi and cellular positioning. **Transactions in GIS**, v. 13, n. s1, p. 5–26, 2009.

ZANDBERGEN, P. A.; BARBEAU, S. J. Positional accuracy of assisted GPS data from high-sensitivity GPS-enabled mobile phones. **Journal of Navigation**, v. 64, n. 3, p. 381–399, 2011.

ZHANG, X. et al. Quality assessment of GNSS observations from an Android N smartphone and positioning performance analysis using time-differenced filtering approach. **GPS Solutions**, v. 22:70, p. 1–11, 2018.

ZHIZHONG MA et al. Experimental evaluation of mobile phone sensors. **24th IET Irish Signals and Systems Conference (ISSC 2013)**, n. June, p. 1–9, 2013.

APÊNDICE A – CÓDIGO GENÉRICO DA MLP

Neste apêndice, encontra-se o código genérico da RNA MLP, implementada por meio da biblioteca TensorFlow. Esta foi usada na presente investigação para geração das observáveis do código e da fase da portadora L2.

```
In [ ]: # Importando os módulos necessários
import pandas as pd
import numpy as np
import matplotlib.pyplot as plt
import seaborn as sns
import tensorflow as tf
from sklearn.model_selection import train_test_split
from sklearn.preprocessing import MinMaxScaler
from datetime import datetime
```

```
In [ ]: # Inicializando a sessão
weight_initializer = tf.random_uniform_initializer(seed = 1)
bias_initializer = tf.zeros_initializer()

# Importando os meus dados
data_x = pd.read_csv('1-Treinamento/L1.txt',header=None).astype('float32')
data_y = pd.read_csv('1-Treinamento/L2.txt',header=None).astype('float32')
data = data_x
data['L2'] = data_y
data.columns = ['L1','L2']
L1_to_pred = pd.read_csv('2-Teste/L1.txt',header=None).astype('float32').values
L2_to_verify = pd.read_csv('2-Teste/L2.txt',header=None).astype('float32').values
Llrixex = pd.read_csv('3-Geracao/Llrixex.txt',header=None).astype('float32').values
```

```
In [ ]: # Definição de parâmetros
n_inputs = 1

nodes_l1 = 8

n_target = 1

# Definição do processador
device = '/device:GPU:0'

# Definição os placeholders (variáveis)
xs = tf.placeholder(dtype = tf.float32,shape = [None,n_inputs])
ys = tf.placeholder(dtype = tf.float32,shape=[None,n_target])

# Definição da estrutura da rede
# Layer 1
W_hidden_1 = tf.Variable(weight_initializer([n_inputs,nodes_l1]))
bias_hidden_1 = tf.Variable(bias_initializer([nodes_l1]))

# Output Layer
W_out = tf.Variable(weight_initializer([nodes_l1,n_target]))
bias_out = tf.Variable(bias_initializer([n_target]))

# Definição do modelo matemático
hidden_1 = tf.nn.tanh(tf.add(tf.matmul(xs, W_hidden_1),bias_hidden_1))

out = tf.add(tf.matmul(hidden_1,W_out),bias_out)

# Definição do Regularizador L2
beta = 0.0001
regularizer = tf.nn.l2_loss(W_hidden_1)
regularizer_out = tf.nn.l2_loss(W_out)

# Definição da função custo e do otimizador
mse = tf.reduce_mean(tf.squared_difference(out,ys))
mse_ok = mse + beta * regularizer + beta * regularizer_out
opt = tf.train.AdamOptimizer().minimize(mse_ok)
```

```

In [ ]: # Criando a lista para a CV
cv = []

# Iniciando a contagem do tempo
start_time = datetime.now()

for cv_times in range(1):
    # Fazendo a sessão
    net = tf.Session()

    # Criando os sets de treinamento e validação com os dados
    data_train, data_valid = train_test_split(data, test_size=0.15, shuffle=True, random_state = 1)

    # Normalizando os dados de 0 à 1
    scaler = MinMaxScaler([-1,1])
    scaler.fit(data.values.reshape(-1,1))
    data_train_n = scaler.transform(data_train)
    data_valid_n = scaler.transform(data_valid)
    Ll_to_pred_n = scaler.transform(Ll_to_pred)
    Llrinex_n = scaler.transform(Llrinex)

    # Criando os sets de X e Y para treinamento e teste
    X_train = data_train_n[:,0]
    y_train = data_train_n[:,1]
    X_valid = data_valid_n[:,0]
    y_valid = data_valid_n[:,1]

    # Rodando o inicializador
    net.run(tf.global_variables_initializer())

    # Número de épocas e tamanho das amostras (batch_size)
    epochs = 4000
    batch_size = 128
    patience_cnt = 0

    # Listas
    mse_train = []
    mse_train.clear()
    mse_valid = []
    mse_valid.clear()
    mse_train_final = []
    mse_train_final.clear()
    mse_valid_final = []
    mse_valid_final.clear()

    print('****20)')
    print('Iniciando o treinamento...')
    print('')

    for e in range(epochs):
        for i in range(0, len(y_train)//batch_size):
            start = i * batch_size
            batch_x = X_train[start:start + batch_size].reshape(batch_size,1)
            batch_y = y_train[start:start + batch_size].reshape(batch_size,1)

            # Rodando o otimizador
            with tf.device(device):
                net.run(opt, feed_dict = {xs: batch_x, ys: batch_y})

            # Mostrando o progresso de treinamento
            if np.mod(i, 50) == 0:

                mse_train.append(net.run(mse, feed_dict = {xs: X_train.reshape(len(X_train),1),
                                                            ys: y_train.reshape(len(y_train),1)}))

                mse_valid.append(net.run(mse, feed_dict = {xs: X_valid.reshape(len(X_valid),1),
                                                            ys: y_valid.reshape(len(y_valid),1)}))

```

```

# Mostrando o progresso do treinamento para as épocas
mse_train_final.append(np.mean(mse_train))
mse_valid_final.append(np.mean(mse_valid))

print('Época: {}'.format(e + 1))
print('MSE para treinamento (final): {:.5E}'.format(mse_train_final[-1]))
print('\033[94mMSE para validação (final): {:.5E}\033[0m'.format(mse_valid_final[-1]))
print('====*20)

# Force stopping
mse_min = 0.00001

if mse_valid_final[-1] <= mse_min:
    break

# Early stopping
patience = 250
min_delta = 0.00001

if e > 1 and (mse_valid_final[-2] - mse_valid_final[-1]) > min_delta:
    patience_cnt += 0
else:
    patience_cnt += 1

    if patience_cnt > patience:
        print('*20)
        print('***20)
        print('Early stopping... -----> Época: {}'.format(e + 1))
        print('***20)
        break

menor = np.min(mse_valid_final)
best_epoch = mse_valid_final.index(menor)
print('*20)
print('\033[1mÉpoca com melhor MSE de validação: {} --> {:.5E}\033[0m'.format(best_epoch + 1, menor))
print('*20)

cv.append(menor)

# Estimativa de valores para o RINEX
L2rinex_n = net.run(out, feed_dict = {xs: L1rinex_n.reshape(len(L1rinex_n), 1)})
L2rinex = scaler.inverse_transform(L2rinex_n.reshape(-1, 1))
np.savetxt('3-Geracao\L2_gerado_{}.txt'.format(cv_times + 1), L2rinex, fmt='%0.3f')
L2rinex = []

# Contagem do tempo de treinamento e validação
elapsed = datetime.now() - start_time
print('*20)
print('*==*15)
print('Duração (hh:mm:ss.ms): {}'.format(elapsed))

mean = np.mean(cv)
print('\033[1mMSE médio para CV: {:.5E}.\033[0m'.format(mean))

```

ANEXO A – RELATÓRIOS DE PROCESSAMENTO – MÉTODO RELATIVO DO LEICA GEO OFFICE V. 5

A seguir, estão expostos os relatórios de processamento pelo método relativo, gerados pelo software Leica Geo Office v. 5. Os documentos estão apresentados na seguinte ordem:

1. Relatório de pós-processamento: Teste 1 (L1);
2. Relatório de pós-processamento: Teste 2 (L1);
3. Relatório de pós-processamento: Teste 3 (L1);
4. Relatório de pós-processamento: Teste 4 (L1);
5. Relatório de pós-processamento: Teste 1 (L1 + L2a);
6. Relatório de pós-processamento: Teste 2 (L1 + L2a);
7. Relatório de pós-processamento: Teste 3 (L1 + L2a);
8. Relatório de pós-processamento: Teste 4 (L1+ L2 a);
9. Relatório de pós-processamento: Teste de *overfitting* (número de épocas = 734);
10. Relatório de pós-processamento: Teste de *overfitting* (número de épocas = 1468).

Processing Summary

15_09_14_Ok

Project Information

Project name: 15_09_14_Ok
 Date created: 07/17/2018 15:28:44
 Time zone: -3h 00'
 Coordinate system name: WGS 1984
 Application software: LEICA Geo Office 5.0
 Start date and time: 09/15/2014 10:00:01
 End date and time: 09/15/2014 10:29:46
 Manually occupied points: 4
 Processing kernel: PSI-Pro 2.0
 Processed: 10/03/2018 20:13:33

Processing Parameters

Parameters	Selected
Cut-off angle:	15°
Ephemeris type:	Broadcast
Solution type:	Automatic
GNSS type:	GPS
Frequency:	L1 only
Fix ambiguities up to:	80 km
Min. duration for float solution (static):	5' 00"
Sampling rate:	Use all
Tropospheric model:	Hopfield
Ionospheric model:	Standard
Use stochastic modelling:	Yes
Min. distance:	8 km
Ionospheric activity:	Automatic

Baseline Overview

MGIN - EESC_original	Reference: MGIN	Rover: EESC_original
Coordinates:		
Latitude:	22° 19' 06.82329" S	22° 00' 17.83114" S
Longitude:	46° 19' 40.88662" W	47° 53' 57.09003" W
Ellip. Hgt:	883.7198 m	824.0789 m
Solution type:	Float	
GNSS type:	GPS	
Frequency:	L1 only	
Ambiguity:	No	
SPJA - EESC_original	Reference: SPJA	Rover: EESC_original

Coordinates:		
Latitude:	21° 14' 27.86391" S	22° 00' 17.85340" S
Longitude:	48° 17' 12.13029" W	47° 53' 57.10730" W
Ellip. Hgt:	570.1997 m	824.6070 m
Solution type:	Float	
GNSS type:	GPS	
Frequency:	L1 only	
Ambiguity:	No	
SPLI - EESC_original	Reference: SPLI	Rover: EESC_original
Coordinates:		
Latitude:	21° 39' 54.73511" S	22° 00' 17.79961" S
Longitude:	49° 44' 01.30229" W	47° 53' 57.02297" W
Ellip. Hgt:	463.2802 m	824.7712 m
Solution type:	Float	
GNSS type:	GPS	
Frequency:	L1 only	
Ambiguity:	No	
SPPI - EESC_original	Reference: SPPI	Rover: EESC_original
Coordinates:		
Latitude:	22° 42' 10.97691" S	22° 00' 17.80140" S
Longitude:	47° 37' 25.03331" W	47° 53' 57.03209" W
Ellip. Hgt:	561.8803 m	825.4341 m
Solution type:	Float	
GNSS type:	GPS	
Frequency:	L1 only	
Ambiguity:	No

Processing Summary

10_01_15_Ok

Project Information

Project name: 10_01_15_Ok
 Date created: 08/07/2018 13:53:10
 Time zone: -3h 00'
 Coordinate system name: WGS 1984
 Application software: LEICA Geo Office 5.0
 Start date and time: 01/10/2015 11:30:01
 End date and time: 01/10/2015 11:59:46
 Manually occupied points: 4
 Processing kernel: PSI-Pro 2.0
 Processed: 10/03/2018 20:10:41

Processing Parameters

Parameters	Selected
Cut-off angle:	15°
Ephemeris type:	Broadcast
Solution type:	Automatic
GNSS type:	Automatic
Frequency:	L1 only
Fix ambiguities up to:	80 km
Min. duration for float solution (static):	5' 00"
Sampling rate:	Use all
Tropospheric model:	Hopfield
Ionospheric model:	Standard
Use stochastic modelling:	Yes
Min. distance:	8 km
Ionospheric activity:	Automatic

Baseline Overview

MGIN - EESC_original	Reference: MGIN	Rover: EESC_original
Coordinates:		
Latitude:	22° 19' 06.82329" S	22° 00' 17.80867" S
Longitude:	46° 19' 40.88662" W	47° 53' 57.10678" W
Ellip. Hgt:	883.7198 m	824.5505 m
Solution type:	Float	
GNSS type:	GPS	
Frequency:	L1 only	
Ambiguity:	No	
SPJA - EESC_original	Reference: SPJA	Rover: EESC_original

Coordinates:		
Latitude:	21° 14' 27.86391" S	22° 00' 17.81784" S
Longitude:	48° 17' 12.13029" W	47° 53' 57.06930" W
Ellip. Hgt:	570.1997 m	824.9334 m
Solution type:	Float	
GNSS type:	GPS	
Frequency:	L1 only	
Ambiguity:	No	
SPLI - EESC_original	Reference: SPLI	Rover: EESC_original
Coordinates:		
Latitude:	21° 39' 54.73511" S	22° 00' 17.80642" S
Longitude:	49° 44' 01.30229" W	47° 53' 57.08186" W
Ellip. Hgt:	463.2802 m	826.0825 m
Solution type:	Float	
GNSS type:	GPS	
Frequency:	L1 only	
Ambiguity:	No	
SPPI - EESC_original	Reference: SPPI	Rover: EESC_original
Coordinates:		
Latitude:	22° 42' 10.97691" S	22° 00' 17.81881" S
Longitude:	47° 37' 25.03331" W	47° 53' 57.07061" W
Ellip. Hgt:	561.8803 m	824.0947 m
Solution type:	Float	
GNSS type:	GPS	
Frequency:	L1 only	
Ambiguity:	No

Processing Summary

10_06_15_Ok

Project Information

Project name: 10_06_15_Ok
 Date created: 08/08/2018 14:21:30
 Time zone: -3h 00'
 Coordinate system name: WGS 1984
 Application software: LEICA Geo Office 5.0
 Start date and time: 06/10/2015 10:30:01
 End date and time: 06/10/2015 10:59:46
 Manually occupied points: 4
 Processing kernel: PSI-Pro 2.0
 Processed: 10/03/2018 20:09:25

Processing Parameters

Parameters	Selected
Cut-off angle:	15°
Ephemeris type:	Broadcast
Solution type:	Automatic
GNSS type:	Automatic
Frequency:	L1 only
Fix ambiguities up to:	80 km
Min. duration for float solution (static):	5' 00"
Sampling rate:	Use all
Tropospheric model:	Hopfield
Ionospheric model:	Standard
Use stochastic modelling:	Yes
Min. distance:	8 km
Ionospheric activity:	Automatic

Baseline Overview

MGIN - EESC_original	Reference: MGIN	Rover: EESC_original
Coordinates:		
Latitude:	22° 19' 06.82329" S	22° 00' 17.83408" S
Longitude:	46° 19' 40.88662" W	47° 53' 57.10793" W
Ellip. Hgt:	883.7198 m	823.3715 m
Solution type:	Float	
GNSS type:	GPS	
Frequency:	L1 only	
Ambiguity:	No	
SPJA - EESC_original	Reference: SPJA	Rover: EESC_original

Coordinates:		
Latitude:	21° 14' 27.86391" S	22° 00' 17.84173" S
Longitude:	48° 17' 12.13029" W	47° 53' 57.11459" W
Ellip. Hgt:	570.1997 m	823.7720 m
Solution type:	Float	
GNSS type:	GPS	
Frequency:	L1 only	
Ambiguity:	No	
SPLI - EESC_original	Reference: SPLI	Rover: EESC_original
Coordinates:		
Latitude:	21° 39' 54.73511" S	22° 00' 17.81843" S
Longitude:	49° 44' 01.30229" W	47° 53' 57.03304" W
Ellip. Hgt:	463.2802 m	825.6149 m
Solution type:	Float	
GNSS type:	GPS	
Frequency:	L1 only	
Ambiguity:	No	
SPPI - EESC_original	Reference: SPPI	Rover: EESC_original
Coordinates:		
Latitude:	22° 42' 10.97691" S	22° 00' 17.83158" S
Longitude:	47° 37' 25.03331" W	47° 53' 57.09177" W
Ellip. Hgt:	561.8803 m	823.1855 m
Solution type:	Float	
GNSS type:	GPS	
Frequency:	L1 only	
Ambiguity:	No

Processing Summary

20_01_16_Ok

Project Information

Project name: 20_01_16_Ok
 Date created: 08/08/2018 14:35:44
 Time zone: -3h 00'
 Coordinate system name: WGS 1984
 Application software: LEICA Geo Office 5.0
 Start date and time: 01/20/2016 12:00:01
 End date and time: 01/20/2016 12:29:46
 Manually occupied points: 4
 Processing kernel: PSI-Pro 2.0
 Processed: 10/03/2018 20:13:03

Processing Parameters

Parameters	Selected
Cut-off angle:	15°
Ephemeris type:	Broadcast
Solution type:	Automatic
GNSS type:	Automatic
Frequency:	L1 only
Fix ambiguities up to:	80 km
Min. duration for float solution (static):	5' 00"
Sampling rate:	Use all
Tropospheric model:	Hopfield
Ionospheric model:	Standard
Use stochastic modelling:	Yes
Min. distance:	8 km
Ionospheric activity:	Automatic

Baseline Overview

MGIN - EESC_original	Reference: MGIN	Rover: EESC_original
Coordinates:		
Latitude:	22° 19' 06.82329" S	22° 00' 17.81967" S
Longitude:	46° 19' 40.88662" W	47° 53' 56.98739" W
Ellip. Hgt:	883.7198 m	822.9921 m
Solution type:	Float	
GNSS type:	GPS	
Frequency:	L1 only	
Ambiguity:	No	
SPJA - EESC_original	Reference: SPJA	Rover: EESC_original

Coordinates:		
Latitude:	21° 14' 27.86391" S	22° 00' 17.81524" S
Longitude:	48° 17' 12.13029" W	47° 53' 57.07387" W
Ellip. Hgt:	570.1997 m	825.6021 m
Solution type:	Float	
GNSS type:	GPS	
Frequency:	L1 only	
Ambiguity:	No	
SPLI - EESC_original	Reference: SPLI	Rover: EESC_original
Coordinates:		
Latitude:	21° 39' 54.73511" S	22° 00' 17.81166" S
Longitude:	49° 44' 01.30229" W	47° 53' 57.09532" W
Ellip. Hgt:	463.2802 m	826.3818 m
Solution type:	Float	
GNSS type:	GPS	
Frequency:	L1 only	
Ambiguity:	No	
SPPI - EESC_original	Reference: SPPI	Rover: EESC_original
Coordinates:		
Latitude:	22° 42' 10.97691" S	22° 00' 17.80990" S
Longitude:	47° 37' 25.03331" W	47° 53' 57.03637" W
Ellip. Hgt:	561.8803 m	823.5480 m
Solution type:	Float	
GNSS type:	GPS	
Frequency:	L1 only	
Ambiguity:	No

Processing Summary

15_09_14_Ok

Project Information

Project name: 15_09_14_Ok
 Date created: 07/17/2018 15:28:44
 Time zone: -3h 00'
 Coordinate system name: WGS 1984
 Application software: LEICA Geo Office 5.0
 Start date and time: 09/15/2014 09:59:46
 End date and time: 09/15/2014 10:29:46
 Manually occupied points: 4
 Processing kernel: PSI-Pro 2.0
 Processed: 10/03/2018 19:46:39

Processing Parameters

Parameters	Selected
Cut-off angle:	15°
Ephemeris type:	Broadcast
Solution type:	Automatic
GNSS type:	GPS
Frequency:	L1 and L2
Fix ambiguities up to:	80 km
Min. duration for float solution (static):	5' 00"
Sampling rate:	Use all
Tropospheric model:	Hopfield
Ionospheric model:	Standard
Use stochastic modelling:	Yes
Min. distance:	8 km
Ionospheric activity:	Automatic

Baseline Overview

MGIN - EESC

Coordinates:

Latitude: 22° 19' 06.82329" S
 Longitude: 46° 19' 40.88662" W
 Ellip. Hgt: 883.7198 m

Solution type: Float
 GNSS type: GPS
 Frequency: L1 and L2
 Ambiguity: No

Reference: MGIN

Rover: EESC

22° 00' 17.80977" S
 47° 53' 57.04936" W
 824.2955 m

SPJA - EESC

Reference: SPJA

Rover: EESC

Coordinates:		
Latitude:	21° 14' 27.86391" S	22° 00' 17.81497" S
Longitude:	48° 17' 12.13029" W	47° 53' 57.03780" W
Ellip. Hgt:	570.1997 m	824.1662 m
Solution type:	Float	
GNSS type:	GPS	
Frequency:	L1 and L2	
Ambiguity:	No	
SPLI - EESC	Reference: SPLI	Rover: EESC
Coordinates:		
Latitude:	21° 39' 54.73511" S	22° 00' 17.81734" S
Longitude:	49° 44' 01.30229" W	47° 53' 57.02861" W
Ellip. Hgt:	463.2802 m	824.1258 m
Solution type:	Float	
GNSS type:	GPS	
Frequency:	L1 and L2	
Ambiguity:	No	
SPPI - EESC	Reference: SPPI	Rover: EESC
Coordinates:		
Latitude:	22° 42' 10.97691" S	22° 00' 17.80759" S
Longitude:	47° 37' 25.03331" W	47° 53' 57.03857" W
Ellip. Hgt:	561.8803 m	824.2357 m
Solution type:	Float	
GNSS type:	GPS	
Frequency:	L1 and L2	
Ambiguity:	No

Processing Summary

10_01_15_Ok

Project Information

Project name: 10_01_15_Ok
 Date created: 08/07/2018 13:53:10
 Time zone: -3h 00'
 Coordinate system name: WGS 1984
 Application software: LEICA Geo Office 5.0
 Start date and time: 01/10/2015 11:29:46
 End date and time: 01/10/2015 11:59:46
 Manually occupied points: 4
 Processing kernel: PSI-Pro 2.0
 Processed: 10/03/2018 19:50:38

Processing Parameters

Parameters	Selected
Cut-off angle:	15°
Ephemeris type:	Broadcast
Solution type:	Automatic
GNSS type:	Automatic
Frequency:	L1 and L2
Fix ambiguities up to:	80 km
Min. duration for float solution (static):	5' 00"
Sampling rate:	Use all
Tropospheric model:	Hopfield
Ionospheric model:	Standard
Use stochastic modelling:	Yes
Min. distance:	8 km
Ionospheric activity:	Automatic

Baseline Overview

MGIN - EESC

Coordinates:

Latitude: 22° 19' 06.82329" S
 Longitude: 46° 19' 40.88662" W
 Ellip. Hgt: 883.7198 m

Solution type: Float
 GNSS type: GPS
 Frequency: L1 and L2
 Ambiguity: No

Reference: MGIN

Rover: EESC

22° 00' 17.81436" S
 47° 53' 57.02792" W
 824.2380 m

SPJA - EESC

Reference: SPJA

Rover: EESC

Coordinates:		
Latitude:	21° 14' 27.86391" S	22° 00' 17.83028" S
Longitude:	48° 17' 12.13029" W	47° 53' 57.03535" W
Ellip. Hgt:	570.1997 m	824.6772 m
Solution type:	Float	
GNSS type:	GPS	
Frequency:	L1 and L2	
Ambiguity:	No	
SPLI - EESC	Reference: SPLI	Rover: EESC
Coordinates:		
Latitude:	21° 39' 54.73511" S	22° 00' 17.83339" S
Longitude:	49° 44' 01.30229" W	47° 53' 57.03338" W
Ellip. Hgt:	463.2802 m	825.2233 m
Solution type:	Float	
GNSS type:	GPS	
Frequency:	L1 and L2	
Ambiguity:	No	
SPPI - EESC	Reference: SPPI	Rover: EESC
Coordinates:		
Latitude:	22° 42' 10.97691" S	22° 00' 17.83147" S
Longitude:	47° 37' 25.03331" W	47° 53' 57.03120" W
Ellip. Hgt:	561.8803 m	823.7683 m
Solution type:	Float	
GNSS type:	GPS	
Frequency:	L1 and L2	
Ambiguity:	No

Processing Summary

10_06_15_Ok

Project Information

Project name: 10_06_15_Ok
 Date created: 08/08/2018 14:21:30
 Time zone: -3h 00'
 Coordinate system name: WGS 1984
 Application software: LEICA Geo Office 5.0
 Start date and time: 06/10/2015 10:29:46
 End date and time: 06/10/2015 10:59:46
 Manually occupied points: 4
 Processing kernel: PSI-Pro 2.0
 Processed: 10/03/2018 19:50:07

Processing Parameters

Parameters	Selected
Cut-off angle:	15°
Ephemeris type:	Broadcast
Solution type:	Automatic
GNSS type:	Automatic
Frequency:	L1 and L2
Fix ambiguities up to:	80 km
Min. duration for float solution (static):	5' 00"
Sampling rate:	Use all
Tropospheric model:	Hopfield
Ionospheric model:	Standard
Use stochastic modelling:	Yes
Min. distance:	8 km
Ionospheric activity:	Automatic

Baseline Overview

MGIN - EESC	Reference: MGIN	Rover: EESC
Coordinates:		
Latitude:	22° 19' 06.82329" S	22° 00' 17.81780" S
Longitude:	46° 19' 40.88662" W	47° 53' 57.03311" W
Ellip. Hgt:	883.7198 m	825.5330 m
Solution type:	Float	
GNSS type:	GPS	
Frequency:	L1 and L2	
Ambiguity:	No	
SPJA - EESC	Reference: SPJA	Rover: EESC

Coordinates:		
Latitude:	21° 14' 27.86391" S	22° 00' 17.81386" S
Longitude:	48° 17' 12.13029" W	47° 53' 57.05466" W
Ellip. Hgt:	570.1997 m	824.8121 m
Solution type:	Float	
GNSS type:	GPS	
Frequency:	L1 and L2	
Ambiguity:	No	
SPLI - EESC	Reference: SPLI	Rover: EESC
Coordinates:		
Latitude:	21° 39' 54.73511" S	22° 00' 17.81859" S
Longitude:	49° 44' 01.30229" W	47° 53' 57.05998" W
Ellip. Hgt:	463.2802 m	824.1958 m
Solution type:	Float	
GNSS type:	GPS	
Frequency:	L1 and L2	
Ambiguity:	No	
SPPI - EESC	Reference: SPPI	Rover: EESC
Coordinates:		
Latitude:	22° 42' 10.97691" S	22° 00' 17.82554" S
Longitude:	47° 37' 25.03331" W	47° 53' 57.05598" W
Ellip. Hgt:	561.8803 m	824.9371 m
Solution type:	Float	
GNSS type:	GPS	
Frequency:	L1 and L2	
Ambiguity:	No

Processing Summary 20_01_16_Ok

Project Information

Project name:	20_01_16_Ok
Date created:	08/08/2018 14:35:44
Time zone:	-3h 00'
Coordinate system name:	WGS 1984
Application software:	LEICA Geo Office 5.0
Start date and time:	01/20/2016 11:59:46
End date and time:	01/20/2016 12:29:46
Manually occupied points:	4
Processing kernel:	PSI-Pro 2.0
Processed:	10/03/2018 19:52:13

Processing Parameters

Parameters	Selected
Cut-off angle:	15°
Ephemeris type:	Broadcast
Solution type:	Automatic
GNSS type:	Automatic
Frequency:	L1 and L2
Fix ambiguities up to:	80 km
Min. duration for float solution (static):	5' 00"
Sampling rate:	Use all
Tropospheric model:	Hopfield
Ionospheric model:	Standard
Use stochastic modelling:	Yes
Min. distance:	8 km
Ionospheric activity:	Automatic

Baseline Overview

MGIN - EESC

Coordinates:

Latitude:	22° 19' 06.82329" S
Longitude:	46° 19' 40.88662" W
Ellip. Hgt:	883.7198 m

Solution type:

Solution type:	Float
GNSS type:	GPS
Frequency:	L1 and L2
Ambiguity:	No

SPJA - EESC

Reference: MGIN

Rover: EESC

Latitude:	22° 00' 17.79651" S
Longitude:	47° 53' 57.05942" W
Ellip. Hgt:	822.2515 m

Reference: SPJA

Rover: EESC

Coordinates:		
Latitude:	21° 14' 27.86391" S	22° 00' 17.81313" S
Longitude:	48° 17' 12.13029" W	47° 53' 57.06745" W
Ellip. Hgt:	570.1997 m	824.2629 m
Solution type:	Float	
GNSS type:	GPS	
Frequency:	L1 and L2	
Ambiguity:	No	
SPLI - EESC	Reference: SPLI	Rover: EESC
Coordinates:		
Latitude:	21° 39' 54.73511" S	22° 00' 17.81407" S
Longitude:	49° 44' 01.30229" W	47° 53' 57.06878" W
Ellip. Hgt:	463.2802 m	824.7957 m
Solution type:	Float	
GNSS type:	GPS	
Frequency:	L1 and L2	
Ambiguity:	No	
SPPI - EESC	Reference: SPPI	Rover: EESC
Coordinates:		
Latitude:	22° 42' 10.97691" S	22° 00' 17.80371" S
Longitude:	47° 37' 25.03331" W	47° 53' 57.06294" W
Ellip. Hgt:	561.8803 m	823.1616 m
Solution type:	Float	
GNSS type:	GPS	
Frequency:	L1 and L2	
Ambiguity:	No

Processing Summary

15_09_14_overfitting

Project Information

Project name: 15_09_14_overfitting
 Date created: 07/17/2018 15:28:44
 Time zone: -3h 00'
 Coordinate system name: WGS 1984
 Application software: LEICA Geo Office 5.0
 Start date and time: 09/15/2014 09:59:46
 End date and time: 09/15/2014 10:29:46
 Manually occupied points: 4
 Processing kernel: PSI-Pro 2.0
 Processed: 10/04/2018 09:41:19

Processing Parameters

Parameters	Selected
Cut-off angle:	15°
Ephemeris type:	Broadcast
Solution type:	Automatic
GNSS type:	GPS
Frequency:	L1 and L2
Fix ambiguities up to:	80 km
Min. duration for float solution (static):	5' 00"
Sampling rate:	Use all
Tropospheric model:	Hopfield
Ionospheric model:	Standard
Use stochastic modelling:	Yes
Min. distance:	8 km
Ionospheric activity:	Automatic

Baseline Overview

MGIN - EESC_734e	Reference: MGIN	Rover: EESC_734e
Coordinates:		
Latitude:	22° 19' 06.82329" S	22° 00' 17.81049" S
Longitude:	46° 19' 40.88662" W	47° 53' 57.05105" W
Ellip. Hgt:	883.7198 m	824.3357 m
Solution type:	Float	
GNSS type:	GPS	
Frequency:	L1 and L2	
Ambiguity:	No	
SPJA - EESC_734e	Reference: SPJA	Rover: EESC_734e

Coordinates:		
Latitude:	21° 14' 27.86391" S	22° 00' 17.81140" S
Longitude:	48° 17' 12.13029" W	47° 53' 57.03863" W
Ellip. Hgt:	570.1997 m	824.3585 m
Solution type:	Float	
GNSS type:	GPS	
Frequency:	L1 and L2	
Ambiguity:	No	
SPLI - EESC_734e	Reference: SPLI	Rover: EESC_734e
Coordinates:		
Latitude:	21° 39' 54.73511" S	22° 00' 17.81844" S
Longitude:	49° 44' 01.30229" W	47° 53' 57.01802" W
Ellip. Hgt:	463.2802 m	824.0264 m
Solution type:	Float	
GNSS type:	GPS	
Frequency:	L1 and L2	
Ambiguity:	No	
SPPI - EESC_734e	Reference: SPPI	Rover: EESC_734e
Coordinates:		
Latitude:	22° 42' 10.97691" S	22° 00' 17.79893" S
Longitude:	47° 37' 25.03331" W	47° 53' 57.02612" W
Ellip. Hgt:	561.8803 m	824.5902 m
Solution type:	Float	
GNSS type:	GPS	
Frequency:	L1 and L2	
Ambiguity:	No

Processing Summary 15_09_14_overfitting

Project Information

Project name: 15_09_14_overfitting
 Date created: 07/17/2018 15:28:44
 Time zone: -3h 00'
 Coordinate system name: WGS 1984
 Application software: LEICA Geo Office 5.0
 Start date and time: 09/15/2014 09:59:46
 End date and time: 09/15/2014 10:29:46
 Manually occupied points: 4
 Processing kernel: PSI-Pro 2.0
 Processed: 10/04/2018 09:42:00

Processing Parameters

Parameters	Selected
Cut-off angle:	15°
Ephemeris type:	Broadcast
Solution type:	Automatic
GNSS type:	GPS
Frequency:	L1 and L2
Fix ambiguities up to:	80 km
Min. duration for float solution (static):	5' 00"
Sampling rate:	Use all
Tropospheric model:	Hopfield
Ionospheric model:	Standard
Use stochastic modelling:	Yes
Min. distance:	8 km
Ionospheric activity:	Automatic

Baseline Overview

MGIN - EESC_1468e	Reference: MGIN	Rover: EESC_1468e
Coordinates:		
Latitude:	22° 19' 06.82329" S	22° 00' 17.81066" S
Longitude:	46° 19' 40.88662" W	47° 53' 57.05137" W
Ellip. Hgt:	883.7198 m	824.3341 m
Solution type:	Float	
GNSS type:	GPS	
Frequency:	L1 and L2	
Ambiguity:	No	
SPJA - EESC_1468e	Reference: SPJA	Rover: EESC_1468e

Coordinates:		
Latitude:	21° 14' 27.86391" S	22° 00' 17.81172" S
Longitude:	48° 17' 12.13029" W	47° 53' 57.03898" W
Ellip. Hgt:	570.1997 m	824.3570 m
Solution type:	Float	
GNSS type:	GPS	
Frequency:	L1 and L2	
Ambiguity:	No	
SPLI - EESC_1468e	Reference: SPLI	Rover: EESC_1468e
Coordinates:		
Latitude:	21° 39' 54.73511" S	22° 00' 17.81870" S
Longitude:	49° 44' 01.30229" W	47° 53' 57.01836" W
Ellip. Hgt:	463.2802 m	824.0254 m
Solution type:	Float	
GNSS type:	GPS	
Frequency:	L1 and L2	
Ambiguity:	No	
SPPI - EESC_1468e	Reference: SPPI	Rover: EESC_1468e
Coordinates:		
Latitude:	22° 42' 10.97691" S	22° 00' 17.79918" S
Longitude:	47° 37' 25.03331" W	47° 53' 57.02647" W
Ellip. Hgt:	561.8803 m	824.5892 m
Solution type:	Float	
GNSS type:	GPS	
Frequency:	L1 and L2	
Ambiguity:	No	

ANEXO B – RELATÓRIOS DE PROCESSAMENTO – MÉTODO PPP DA SOLUÇÃO ON-LINE DO IBGE

Neste anexo encontram-se os relatórios de processamento pelo método PPP, fornecidos pela solução on-line do IBGE (IBGE-PPP). Os documentos estão apresentados na seguinte ordem:

1. Relatório de pós-processamento: Teste 5 (L1);
2. Relatório de pós-processamento: Teste 6 (L1);
3. Relatório de pós-processamento: Teste 7 (L1);
4. Relatório de pós-processamento: Teste 8 (L1);
5. Relatório de pós-processamento: Teste 5 (L3 = Combinação da L1 com a L2a);
6. Relatório de pós-processamento: Teste 6 (L3 = Combinação da L1 com a L2a);
7. Relatório de pós-processamento: Teste 7 (L3 = Combinação da L1 com a L2a);
8. Relatório de pós-processamento: Teste 8 (L3 = Combinação da L1 com a L2a).

Instituto Brasileiro de Geografia e Estatística
Relatório do Posicionamento por Ponto Preciso (PPP)

Sumário do Processamento do marco: Geo++

Início: AAAA/MM/DD HH:MM:SS,SS	2017/12/12 18:10:00,00
Fim: AAAA/MM/DD HH:MM:SS,SS	2017/12/12 18:39:45,00
Modo de Operação do Usuário:	ESTÁTICO
Observação processada:	CÓDIGO & FASE
Modelo da Antena:	NÃO DISPONÍVEL
Órbitas dos satélites: ¹	FINAL
Frequência processada:	L1
Intervalo do processamento(s):	15,00
Sigma² da pseudodistância(m):	5,000
Sigma da portadora(m):	0,300
Altura da Antena³(m):	0,000
Ângulo de Elevação(graus):	10,000
Resíduos da pseudodistância(m):	7,19 GPS
Resíduos da fase da portadora(cm):	38,14 GPS

Coordenadas SIRGAS

	Latitude(gms)	Longitude(gms)	Alt. Geo.(m)	UTM N(m)	UTM E(m)	MC
Em 2000.4 (É a que deve ser usada) ⁴	-21° 58' 54,1092"	-47° 52' 44,3451"	852,42	7566401.456	202699.975	-45
Na data do levantamento ⁵	-21° 58' 54,1026"	-47° 52' 44,3467"	852,42	7566401.658	202699.925	-45
Sigma(95%)⁶ (m)	1,843	1,745	4,514			
Modelo Geoidal	MAPGEO2015					
Ondulação Geoidal (m)	-6,31					
Altitude Ortométrica (m)	858,73					

Precisão esperada para um levantamento estático (metros)

Tipo de Receptor	Uma frequência		Duas frequências	
	Planimétrico	Altimétrico	Planimétrico	Altimétrico
Após 1 hora	0,700	0,600	0,040	0,040
Após 2 horas	0,330	0,330	0,017	0,018
Após 4 horas	0,170	0,220	0,009	0,010
Após 6 horas	0,120	0,180	0,005	0,008

¹ Órbitas obtidas do International GNSS Service (IGS) ou do Natural Resources of Canada (NRCAN).

² O termo "Sigma" é referente ao desvio-padrão.

³ Distância Vertical do Marco ao Plano de Referência da Antena (PRA).

⁴ A coordenada oficial na data de referência do Sistema SIRGAS, ou seja, 2000.4. A redução de velocidade foi feita na data do levantamento, utilizando o modelo VEMOS em 2000.4.

⁵ A data de levantamento considerada é a data de início da sessão.

⁶ Este desvio-padrão representa a confiabilidade interna do processamento e não a exatidão da coordenada.

Os resultados apresentados neste relatório dependem da qualidade dos dados enviados e do correto preenchimento das informações por parte do usuário. Em caso de dúvidas, críticas ou sugestões contate: ibge@ibge.gov.br ou pelo telefone 0800-7218181. Este serviço de posicionamento faz uso do aplicativo de processamento CSRS-PPP desenvolvido pelo Geodetic Survey Division of Natural Resources of Canada (NRCAN).

Processamento autorizado para uso do IBGE.

Instituto Brasileiro de Geografia e Estatística
Relatório do Posicionamento por Ponto Preciso (PPP)

Sumário do Processamento do marco: Geo++

Início: AAAA/MM/DD HH:MM:SS,SS	2018/09/24 20:04:59,99
Fim: AAAA/MM/DD HH:MM:SS,SS	2018/09/24 20:35:00,00
Modo de Operação do Usuário:	ESTÁTICO
Observação processada:	CÓDIGO & FASE
Modelo da Antena:	NÃO DISPONÍVEL
Órbitas dos satélites: ¹	FINAL
Frequência processada:	L1
Intervalo do processamento(s):	15,00
Sigma² da pseudodistância(m):	5,000
Sigma da portadora(m):	0,300
Altura da Antena³(m):	0,000
Ângulo de Elevação(graus):	10,000
Resíduos da pseudodistância(m):	9,35 GPS
Resíduos da fase da portadora(cm):	38,16 GPS

Coordenadas SIRGAS

	Latitude(gms)	Longitude(gms)	Alt. Geo.(m)	UTM N(m)	UTM E(m)	MC
Em 2000.4 (É a que deve ser usada) ⁴	-21° 58' 54,1350"	-47° 52' 44,2601"	852,47	7566400.708	202702.429	-45
Na data do levantamento ⁵	-21° 58' 54,1281"	-47° 52' 44,2618"	852,47	7566400.919	202702.377	-45
Sigma(95%)⁶ (m)	2,061	2,097	3,626			
Modelo Geoidal	MAPGEO2015					
Ondulação Geoidal (m)	-6,31					
Altitude Ortométrica (m)	858,78					

Precisão esperada para um levantamento estático (metros)

Tipo de Receptor	Uma frequência		Duas frequências	
	Planimétrico	Altimétrico	Planimétrico	Altimétrico
Após 1 hora	0,700	0,600	0,040	0,040
Após 2 horas	0,330	0,330	0,017	0,018
Após 4 horas	0,170	0,220	0,009	0,010
Após 6 horas	0,120	0,180	0,005	0,008

¹ Órbitas obtidas do International GNSS Service (IGS) ou do Natural Resources of Canada (NRCAN).

² O termo "Sigma" é referente ao desvio-padrão.

³ Distância Vertical do Marco ao Plano de Referência da Antena (PRA).

⁴ A coordenada oficial na data de referência do Sistema SIRGAS, ou seja, 2000.4. A redução de velocidade foi feita na data do levantamento, utilizando o modelo VEMOS em 2000.4.

⁵ A data de levantamento considerada é a data de início da sessão.

⁶ Este desvio-padrão representa a confiabilidade interna do processamento e não a exatidão da coordenada.

Os resultados apresentados neste relatório dependem da qualidade dos dados enviados e do correto preenchimento das informações por parte do usuário. Em caso de dúvidas, críticas ou sugestões contate: ibge@ibge.gov.br ou pelo telefone 0800-7218181. Este serviço de posicionamento faz uso do aplicativo de processamento CSRS-PPP desenvolvido pelo Geodetic Survey Division of Natural Resources of Canada (NRCAN).

Processamento autorizado para uso do IBGE.

Instituto Brasileiro de Geografia e Estatística
Relatório do Posicionamento por Ponto Preciso (PPP)

Sumário do Processamento do marco: Geo++

Início: AAAA/MM/DD HH:MM:SS,SS	2018/09/25 09:14:59,99
Fim: AAAA/MM/DD HH:MM:SS,SS	2018/09/25 09:44:45,00
Modo de Operação do Usuário:	ESTÁTICO
Observação processada:	CÓDIGO & FASE
Modelo da Antena:	NÃO DISPONÍVEL
Órbitas dos satélites: ¹	FINAL
Frequência processada:	L1
Intervalo do processamento(s):	15,00
Sigma² da pseudodistância(m):	5,000
Sigma da portadora(m):	0,300
Altura da Antena³(m):	0,000
Ângulo de Elevação(graus):	10,000
Resíduos da pseudodistância(m):	6,43 GPS
Resíduos da fase da portadora(cm):	36,25 GPS

Coordenadas SIRGAS

	Latitude(gms)	Longitude(gms)	Alt. Geo.(m)	UTM N(m)	UTM E(m)	MC
Em 2000.4 (É a que deve ser usada) ⁴	-21° 58' 54,1059"	-47° 52' 44,2932"	849,71	7566401.586	202701.462	-45
Na data do levantamento ⁵	-21° 58' 54,0990"	-47° 52' 44,2949"	849,71	7566401.797	202701.410	-45
Sigma(95%)⁶ (m)	1,674	1,844	4,313			
Modelo Geoidal	MAPGEO2015					
Ondulação Geoidal (m)	-6,31					
Altitude Ortométrica (m)	856,02					

Precisão esperada para um levantamento estático (metros)

Tipo de Receptor	Uma frequência		Duas frequências	
	Planimétrico	Altimétrico	Planimétrico	Altimétrico
Após 1 hora	0,700	0,600	0,040	0,040
Após 2 horas	0,330	0,330	0,017	0,018
Após 4 horas	0,170	0,220	0,009	0,010
Após 6 horas	0,120	0,180	0,005	0,008

¹ Órbitas obtidas do International GNSS Service (IGS) ou do Natural Resources of Canada (NRCAN).

² O termo "Sigma" é referente ao desvio-padrão.

³ Distância Vertical do Marco ao Plano de Referência da Antena (PRA).

⁴ A coordenada oficial na data de referência do Sistema SIRGAS, ou seja, 2000.4. A redução de velocidade foi feita na data do levantamento, utilizando o modelo VEMOS em 2000.4.

⁵ A data de levantamento considerada é a data de início da sessão.

⁶ Este desvio-padrão representa a confiabilidade interna do processamento e não a exatidão da coordenada.

Os resultados apresentados neste relatório dependem da qualidade dos dados enviados e do correto preenchimento das informações por parte do usuário. Em caso de dúvidas, críticas ou sugestões contate: ibge@ibge.gov.br ou pelo telefone 0800-7218181. Este serviço de posicionamento faz uso do aplicativo de processamento CSRS-PPP desenvolvido pelo Geodetic Survey Division of Natural Resources of Canada (NRCAN).

Processamento autorizado para uso do IBGE.

Instituto Brasileiro de Geografia e Estatística
Relatório do Posicionamento por Ponto Preciso (PPP)

Sumário do Processamento do marco: Geo++

Início: AAAA/MM/DD HH:MM:SS,SS	2017/12/08 19:25:00,00
Fim: AAAA/MM/DD HH:MM:SS,SS	2017/12/08 19:54:45,00
Modo de Operação do Usuário:	ESTÁTICO
Observação processada:	CÓDIGO & FASE
Modelo da Antena:	NÃO DISPONÍVEL
Órbitas dos satélites: ¹	FINAL
Frequência processada:	L1
Intervalo do processamento(s):	15,00
Sigma² da pseudodistância(m):	5,000
Sigma da portadora(m):	0,300
Altura da Antena³(m):	0,000
Ângulo de Elevação(graus):	10,000
Resíduos da pseudodistância(m):	6,51 GPS
Resíduos da fase da portadora(cm):	40,41 GPS

Coordenadas SIRGAS

	Latitude(gms)	Longitude(gms)	Alt. Geo.(m)	UTM N(m)	UTM E(m)	MC
Em 2000.4 (É a que deve ser usada) ⁴	-21° 12' 08,4077"	-47° 52' 04,6376"	625,15	7652762.392	202247.952	-45
Na data do levantamento ⁵	-21° 12' 08,4011"	-47° 52' 04,6392"	625,15	7652762.594	202247.902	-45
Sigma(95%)⁶ (m)	1,745	1,752	4,002			
Modelo Geoidal	MAPGEO2015					
Ondulação Geoidal (m)	-6,73					
Altitude Ortométrica (m)	631,88					

Precisão esperada para um levantamento estático (metros)

Tipo de Receptor	Uma frequência		Duas frequências	
	Planimétrico	Altimétrico	Planimétrico	Altimétrico
Após 1 hora	0,700	0,600	0,040	0,040
Após 2 horas	0,330	0,330	0,017	0,018
Após 4 horas	0,170	0,220	0,009	0,010
Após 6 horas	0,120	0,180	0,005	0,008

¹ Órbitas obtidas do International GNSS Service (IGS) ou do Natural Resources of Canada (NRCAN).

² O termo "Sigma" é referente ao desvio-padrão.

³ Distância Vertical do Marco ao Plano de Referência da Antena (PRA).

⁴ A coordenada oficial na data de referência do Sistema SIRGAS, ou seja, 2000.4. A redução de velocidade foi feita na data do levantamento, utilizando o modelo VEMOS em 2000.4.

⁵ A data de levantamento considerada é a data de início da sessão.

⁶ Este desvio-padrão representa a confiabilidade interna do processamento e não a exatidão da coordenada.

Os resultados apresentados neste relatório dependem da qualidade dos dados enviados e do correto preenchimento das informações por parte do usuário. Em caso de dúvidas, críticas ou sugestões contate: ibge@ibge.gov.br ou pelo telefone 0800-7218181. Este serviço de posicionamento faz uso do aplicativo de processamento CSRS-PPP desenvolvido pelo Geodetic Survey Division of Natural Resources of Canada (NRCAN).

Processamento autorizado para uso do IBGE.

Instituto Brasileiro de Geografia e Estatística
Relatório do Posicionamento por Ponto Preciso (PPP)

Sumário do Processamento do marco: Geo++

Início: AAAA/MM/DD HH:MM:SS,SS	2017/12/12 18:10:00,00
Fim: AAAA/MM/DD HH:MM:SS,SS	2017/12/12 18:39:45,00
Modo de Operação do Usuário:	ESTÁTICO
Observação processada:	CÓDIGO & FASE
Modelo da Antena:	NÃO DISPONÍVEL
Órbitas dos satélites: ¹	FINAL
Frequência processada:	L3
Intervalo do processamento(s):	15,00
Sigma² da pseudodistância(m):	5,000
Sigma da portadora(m):	0,010
Altura da Antena³(m):	0,000
Ângulo de Elevação(graus):	10,000
Resíduos da pseudodistância(m):	5,25 GPS
Resíduos da fase da portadora(cm):	0,00 GPS

Coordenadas SIRGAS

	Latitude(gms)	Longitude(gms)	Alt. Geo.(m)	UTM N(m)	UTM E(m)	MC
Em 2000.4 (É a que deve ser usada) ⁴	-21° 58' 54,1428"	-47° 52' 44,3394"	850,64	7566400.425	202700.158	-45
Na data do levantamento ⁵	-21° 58' 54,1362"	-47° 52' 44,3410"	850,64	7566400.627	202700.108	-45
Sigma(95%)⁶ (m)	2,173	1,975	4,938			
Modelo Geoidal	MAPGEO2015					
Ondulação Geoidal (m)	-6,31					
Altitude Ortométrica (m)	856,95					

Precisão esperada para um levantamento estático (metros)

Tipo de Receptor	Uma frequência		Duas frequências	
	Planimétrico	Altimétrico	Planimétrico	Altimétrico
Após 1 hora	0,700	0,600	0,040	0,040
Após 2 horas	0,330	0,330	0,017	0,018
Após 4 horas	0,170	0,220	0,009	0,010
Após 6 horas	0,120	0,180	0,005	0,008

¹ Órbitas obtidas do International GNSS Service (IGS) ou do Natural Resources of Canada (NRCAN).

² O termo "Sigma" é referente ao desvio-padrão.

³ Distância Vertical do Marco ao Plano de Referência da Antena (PRA).

⁴ A coordenada oficial na data de referência do Sistema SIRGAS, ou seja, 2000.4. A redução de velocidade foi feita na data do levantamento, utilizando o modelo VEMOS em 2000.4.

⁵ A data de levantamento considerada é a data de início da sessão.

⁶ Este desvio-padrão representa a confiabilidade interna do processamento e não a exatidão da coordenada.

Os resultados apresentados neste relatório dependem da qualidade dos dados enviados e do correto preenchimento das informações por parte do usuário. Em caso de dúvidas, críticas ou sugestões contate: ibge@ibge.gov.br ou pelo telefone 0800-7218181. Este serviço de posicionamento faz uso do aplicativo de processamento CSRS-PPP desenvolvido pelo Geodetic Survey Division of Natural Resources of Canada (NRCAN).

Processamento autorizado para uso do IBGE.

Instituto Brasileiro de Geografia e Estatística
Relatório do Posicionamento por Ponto Preciso (PPP)

Sumário do Processamento do marco: Geo++

Início: AAAA/MM/DD HH:MM:SS,SS	2018/09/24 20:04:59,99
Fim: AAAA/MM/DD HH:MM:SS,SS	2018/09/24 20:35:00,00
Modo de Operação do Usuário:	ESTÁTICO
Observação processada:	CÓDIGO & FASE
Modelo da Antena:	NÃO DISPONÍVEL
Órbitas dos satélites: ¹	FINAL
Frequência processada:	L3
Intervalo do processamento(s):	15,00
Sigma² da pseudodistância(m):	5,000
Sigma da portadora(m):	0,010
Altura da Antena³(m):	0,000
Ângulo de Elevação(graus):	10,000
Resíduos da pseudodistância(m):	8,81 GPS
Resíduos da fase da portadora(cm):	0,00 GPS

Coordenadas SIRGAS

	Latitude(gms)	Longitude(gms)	Alt. Geo.(m)	UTM N(m)	UTM E(m)	MC
Em 2000.4 (É a que deve ser usada) ⁴	-21° 58' 54,1147"	-47° 52' 44,3328"	845,19	7566401.293	202700.331	-45
Na data do levantamento ⁵	-21° 58' 54,1078"	-47° 52' 44,3345"	845,19	7566401.505	202700.278	-45
Sigma(95%)⁶ (m)	5,121	5,746	9,082			
Modelo Geoidal	MAPGEO2015					
Ondulação Geoidal (m)	-6,31					
Altitude Ortométrica (m)	851,50					

Precisão esperada para um levantamento estático (metros)

Tipo de Receptor	Uma frequência		Duas frequências	
	Planimétrico	Altimétrico	Planimétrico	Altimétrico
Após 1 hora	0,700	0,600	0,040	0,040
Após 2 horas	0,330	0,330	0,017	0,018
Após 4 horas	0,170	0,220	0,009	0,010
Após 6 horas	0,120	0,180	0,005	0,008

¹ Órbitas obtidas do International GNSS Service (IGS) ou do Natural Resources of Canada (NRCAN).

² O termo "Sigma" é referente ao desvio-padrão.

³ Distância Vertical do Marco ao Plano de Referência da Antena (PRA).

⁴ A coordenada oficial na data de referência do Sistema SIRGAS, ou seja, 2000.4. A redução de velocidade foi feita na data do levantamento, utilizando o modelo VEMOS em 2000.4.

⁵ A data de levantamento considerada é a data de início da sessão.

⁶ Este desvio-padrão representa a confiabilidade interna do processamento e não a exatidão da coordenada.

Os resultados apresentados neste relatório dependem da qualidade dos dados enviados e do correto preenchimento das informações por parte do usuário. Em caso de dúvidas, críticas ou sugestões contate: ibge@ibge.gov.br ou pelo telefone 0800-7218181. Este serviço de posicionamento faz uso do aplicativo de processamento CSRS-PPP desenvolvido pelo Geodetic Survey Division of Natural Resources of Canada (NRCAN).

Processamento autorizado para uso do IBGE.

Instituto Brasileiro de Geografia e Estatística
Relatório do Posicionamento por Ponto Preciso (PPP)

Sumário do Processamento do marco: Geo++

Início: AAAA/MM/DD HH:MM:SS,SS	2018/09/25 09:14:59,99
Fim: AAAA/MM/DD HH:MM:SS,SS	2018/09/25 09:44:45,00
Modo de Operação do Usuário:	ESTÁTICO
Observação processada:	CÓDIGO & FASE
Modelo da Antena:	NÃO DISPONÍVEL
Órbitas dos satélites: ¹	FINAL
Frequência processada:	L3
Intervalo do processamento(s):	15,00
Sigma² da pseudodistância(m):	5,000
Sigma da portadora(m):	0,010
Altura da Antena³(m):	0,000
Ângulo de Elevação(graus):	10,000
Resíduos da pseudodistância(m):	5,27 GPS
Resíduos da fase da portadora(cm):	0,00 GPS

Coordenadas SIRGAS

	Latitude(gms)	Longitude(gms)	Alt. Geo.(m)	UTM N(m)	UTM E(m)	MC
Em 2000.4 (É a que deve ser usada) ⁴	-21° 58' 54,1469"	-47° 52' 44,3252"	849,25	7566400.307	202700.568	-45
Na data do levantamento ⁵	-21° 58' 54,1400"	-47° 52' 44,3269"	849,25	7566400.518	202700.515	-45
Sigma(95%)⁶ (m)	2,051	2,185	5,063			
Modelo Geoidal	MAPGEO2015					
Ondulação Geoidal (m)	-6,31					
Altitude Ortométrica (m)	855,56					

Precisão esperada para um levantamento estático (metros)

Tipo de Receptor	Uma frequência		Duas frequências	
	Planimétrico	Altimétrico	Planimétrico	Altimétrico
Após 1 hora	0,700	0,600	0,040	0,040
Após 2 horas	0,330	0,330	0,017	0,018
Após 4 horas	0,170	0,220	0,009	0,010
Após 6 horas	0,120	0,180	0,005	0,008

¹ Órbitas obtidas do International GNSS Service (IGS) ou do Natural Resources of Canada (NRCAN).

² O termo "Sigma" é referente ao desvio-padrão.

³ Distância Vertical do Marco ao Plano de Referência da Antena (PRA).

⁴ A coordenada oficial na data de referência do Sistema SIRGAS, ou seja, 2000.4. A redução de velocidade foi feita na data do levantamento, utilizando o modelo VEMOS em 2000.4.

⁵ A data de levantamento considerada é a data de início da sessão.

⁶ Este desvio-padrão representa a confiabilidade interna do processamento e não a exatidão da coordenada.

Os resultados apresentados neste relatório dependem da qualidade dos dados enviados e do correto preenchimento das informações por parte do usuário. Em caso de dúvidas, críticas ou sugestões contate: ibge@ibge.gov.br ou pelo telefone 0800-7218181. Este serviço de posicionamento faz uso do aplicativo de processamento CSRS-PPP desenvolvido pelo Geodetic Survey Division of Natural Resources of Canada (NRCAN).

Processamento autorizado para uso do IBGE.

Instituto Brasileiro de Geografia e Estatística
Relatório do Posicionamento por Ponto Preciso (PPP)

Sumário do Processamento do marco: Geo++

Início: AAAA/MM/DD HH:MM:SS,SS	2017/12/08 19:25:00,00
Fim: AAAA/MM/DD HH:MM:SS,SS	2017/12/08 19:54:45,00
Modo de Operação do Usuário:	ESTÁTICO
Observação processada:	CÓDIGO & FASE
Modelo da Antena:	NÃO DISPONÍVEL
Órbitas dos satélites: ¹	FINAL
Frequência processada:	L3
Intervalo do processamento(s):	15,00
Sigma² da pseudodistância(m):	5,000
Sigma da portadora(m):	0,010
Altura da Antena³(m):	0,000
Ângulo de Elevação(graus):	10,000
Resíduos da pseudodistância(m):	4,69 GPS
Resíduos da fase da portadora(cm):	0,00 GPS

Coordenadas SIRGAS

	Latitude(gms)	Longitude(gms)	Alt. Geo.(m)	UTM N(m)	UTM E(m)	MC
Em 2000.4 (É a que deve ser usada) ⁴	-21° 12' 08,3989"	-47° 52' 04,6978"	618,59	7652762.632	202246.210	-45
Na data do levantamento ⁵	-21° 12' 08,3923"	-47° 52' 04,6994"	618,59	7652762.834	202246.160	-45
Sigma(95%)⁶ (m)	1,713	1,753	3,935			
Modelo Geoidal	MAPGEO2015					
Ondulação Geoidal (m)	-6,73					
Altitude Ortométrica (m)	625,32					

Precisão esperada para um levantamento estático (metros)

Tipo de Receptor	Uma frequência		Duas frequências	
	Planimétrico	Altimétrico	Planimétrico	Altimétrico
Após 1 hora	0,700	0,600	0,040	0,040
Após 2 horas	0,330	0,330	0,017	0,018
Após 4 horas	0,170	0,220	0,009	0,010
Após 6 horas	0,120	0,180	0,005	0,008

¹ Órbitas obtidas do International GNSS Service (IGS) ou do Natural Resources of Canada (NRCAN).

² O termo "Sigma" é referente ao desvio-padrão.

³ Distância Vertical do Marco ao Plano de Referência da Antena (PRA).

⁴ A coordenada oficial na data de referência do Sistema SIRGAS, ou seja, 2000.4. A redução de velocidade foi feita na data do levantamento, utilizando o modelo VEMOS em 2000.4.

⁵ A data de levantamento considerada é a data de início da sessão.

⁶ Este desvio-padrão representa a confiabilidade interna do processamento e não a exatidão da coordenada.

Os resultados apresentados neste relatório dependem da qualidade dos dados enviados e do correto preenchimento das informações por parte do usuário. Em caso de dúvidas, críticas ou sugestões contate: ibge@ibge.gov.br ou pelo telefone 0800-7218181. Este serviço de posicionamento faz uso do aplicativo de processamento CSRS-PPP desenvolvido pelo Geodetic Survey Division of Natural Resources of Canada (NRCAN).

Processamento autorizado para uso do IBGE.

Desvio Padrão e Diferença da Coordenada a Priori
Rinex.17o