

REPRESENTAÇÃO EM MALHAS 3D A PARTIR DE DADOS DE TEXTURA DO SOLO INTERPOLADOS MEDIANTE REDE NEURAL ARTIFICIAL: ESTUDO DE CASO FESCON - PONTA GROSSA - PR

REPRESENTATION IN 3D MESHES FROM THE INTERPOLATED SOIL TEXTURE DATA BY ARTIFICIAL NEURAL NETWORK: CASE STUDY FESCON - PONTA GROSSA - PR

Giovane Conti¹, Kelly Lais Wiggers¹, Selma Regina Aranha Ribeiro¹

¹ Universidade Estadual de Ponta Grossa (UEPG), Ponta Grossa, PR, Brasil

Correspondência para: Giovane Conti (giovane.conti@gmail.com)

doi: 10.12957/geouerj.2016.12310

Recebido em: 6 ago. 2014 | Aceito em: 16 ago. 2015



RESUMO

As propriedades físicas do solo possuem grande impacto em seu comportamento, e estas características resultam na classificação do perfil e aptidão do solo. Em se tratando de Agricultura de Precisão, é importante identificar no solo sua distribuição espacial granulométrica ou textura. Desta forma, a partir de dados granulométricos georreferenciados (areia, silte e argila) coletados de solos de uma gleba da Fazenda Escola Capão-da-Onça (FESCON Ponta Grossa - PR), foi realizada a interpolação, utilizando Função de Base Radial (RBF) e treinamento supervisionado por Rede Neural Artificial (RNA), comparando os resultados obtidos em um modelo 3D, a fim de verificar o desempenho da RNA utilizada. Verificou-se principalmente que as representações da RNA com o atributo areia foi suavizada quando interpolado os dados granulométricos em relação ao RBF. Já os atributos argila e silte ocorreu algumas variações entre RNA e RBF, não suavizando sempre.

Palavras-chave: Dados de textura do solo; redes neurais artificiais; representação em malhas 3D.

ABSTRACT

The physical properties of the soil have great impact on their behavior, and these characteristics result in classification of the profile and soil suitability. In the case of Precision Agriculture is important to identify in the soil particle size space distribution or texture. Thus, from granulometric georeferenced data (sand, silt and clay) soils collected from a farmland Farm School Capão-da-Onça (FESCON Ponta Grossa - PR), was performed interpolation using Radial Basis Function (RBF) and supervised training for Artificial Neural Network (ANN), comparing the results obtained on a 3D model in order to verify the performance of the RNA used. It was found that especially the representations of RNA with the sand attribute was smoothed when interpolated the granulometric data in relation to RBF. The attributes clay and silt had some variations between ANN and RBF, it doesn't always smoothed.

Keywords: interpolates soil texture; artificial neural network; 3D meshes representation.

INTRODUÇÃO

As técnicas de Sistemas de Informação Geográfica (SIG) são adequadas para estudos do meio ambiente, visto que proporcionam a manipulação, organização e modelagens dos dados obtidos em informações relevantes.

O termo Sistemas de Informações Geográficas (SIG) refere-se àqueles sistemas que efetuam o tratamento computacional de dados geográficos. Um SIG armazena a geometria e os atributos dos dados que estão georreferenciados, isto é, localizados na superfície terrestre e numa projeção cartográfica determinada. Os dados tratados em geoprocessamento têm como principal característica a diversidade de fontes geradoras e de formatos apresentados. (ASSAD, 1998).

Um modelo de representação de dados em SIG é o modelo digital de elevação ou de terreno (MDE ou MDT), como por exemplo, a grade regular. Esta grade pode gerar uma representação matricial onde cada elemento da matriz está associado a um número referente a um atributo, tal como altitude, cota, temperatura, textura de solos, dentre outros. Para a geração da grade, torna-se necessário estimar, a partir de interpoladores matemáticos, os valores para as células que não possuem medidas de atributos ou numéricas. Neste estudo utiliza-se o MDE para a representação da textura do solo, isto é modelos de três teores de areia, silte e argila.

As propriedades físicas do solo possuem grande impacto em seu comportamento e em como deve ser efetuado seu manejo. Suas propriedades físicas são caracterizadas pela cor, textura (granulometria), estrutura, porosidade, consistência e permeabilidade. Todas essas características resultam na classificação do perfil e aptidão do solo (BRADY e WEIL, 2008). O termo granulometria é utilizado para identificar o conjunto de partículas do solo, desde as mais finas, como argila até as mais grosseiras, como cascalho e são divididas em 3 grupos: areia, silte e argila (IBGE, 2007).

A necessidade de incrementar a produção agrícola é uma realidade para a humanidade, neste contexto as técnicas e métodos são imprescindíveis na agricultura. Para o desenvolvimento dela, voltado à preservação do meio ambiente, respeitando a heterogeneidade dos solos e usando adequadamente dos insumos agrícolas, a Agricultura de Precisão (AP) é um fato.

Segundo MAPA (2011), a AP é um sistema de gerenciamento agrícola, baseado na variação espacial das propriedades do solo e das plantas encontradas nas lavouras. Seu objetivo é a otimização do lucro, sustentabilidade e proteção do meio ambiente.

Em se tratando de AP / culturas é importante identificar no solo sua distribuição espacial granulométrica ou textura do solo. A fração areia, por possuir o maior tamanho, permite maior permeabilidade à água e ao ar do solo, possui baixa capacidade de retenção de água e é considerada não-coesivas. A fração silte possui poros menores, porém em maior quantidade, retendo mais água e menor drenagem do que areia. A fração argila, por possuir um diâmetro reduzido, apresenta grande área superficial específica, o que leva a uma alta retenção de água e fluxo lento de ar e também alta pegajosidade quando úmida e alta coesão quando seca (Brady e Weil, 2008), devido aos fatos, a fração do solo que mais influencia em seu comportamento físico é a argila (Reichardt e Timm, 2004). A fração argila também é primordial no que diz respeito a fertilidade do solo, capacidade de troca de cátions, disponibilidade de nutrientes, capacidade de armazenamento de água, tendência à compactação, porosidade e permeabilidade, mais detalhes sobre fração argila em PAIVA NETO, 1942.

Como já mencionado, a interpolação espacial é o procedimento para se estimar valores de propriedades de locais não amostrados, baseando-se em valores de dados observados em locais conhecidos (Burrough, 1986).

Para interpolar dados espacialmente é necessário a construção de uma malha envolvendo todo o domínio dos pontos amostrais. Segundo Carmo (2001) apud Mazzini e Schettini (2009), há diversos métodos de gradeamento, sendo capazes de gerar grades regulares e irregulares.

Segundo Mazzini e Schettini (2009), a Função de Base Radial (RBF) é um conjunto de métodos de interpolação exatos. A maioria dos métodos são derivações de spline, com características similares uns dos outros. O referido autor também destaca que o método de derivação multi-quadrático é o padrão automático no Surfer®, pois é considerado o melhor na maioria dos casos.

O objetivo deste trabalho é, a partir de dados georreferenciados coletados de solos de uma gleba da Fazenda Escola Capão-da-Onça (FESCON Ponta Grossa - PR), realizar a interpolação, utilizando o RBF (Função de Base Radial) e treinamento supervisionado por Rede Neural Artificial (RNA),

comparando os resultados obtidos em um modelo 3D, a fim de verificar o desempenho da RNA utilizada.

Redes Neurais Artificiais

As RNA (Redes Neurais Artificiais) são motivadas pelo princípio do cérebro humano processar informações de forma diferente do computador convencional. Ou seja, o cérebro humano é considerado um computador altamente complexo, não linear e paralelo, com capacidade de organizar seus constituintes estruturais conhecidos por neurônios e também realiza certos processamentos como reconhecimento de padrões, percepção e controle motor de forma mais eficiente que um computador digital (HAYKIN, 1999).

O autor referido acima define a rede neural como uma máquina projetada para modelar a maneira como o cérebro realiza tarefas e funções de interesse e é implementada por componentes eletrônicos ou simulada por programação em um computador.

Rezende (2005) destaca que as RNA são capazes de resolver problemas de aproximação, predição, categorização, otimização e classificação. Alguns exemplos de utilização são: reconhecimento de caracteres, reconhecimento de voz, predições de séries temporais e modelagem de processos.

Segundo Chen e Leou (2012) o uso de redes neurais com interpoladores possui resultados rápidos com alta complexidade computacional para seleção de conjunto de cores em imagens. Gorgens et al (2009) afirma que a interpolação linear como método de normalização fornece melhores resultados e a equalização dos dados melhora a capacidade de predição da rede neural. Para Nourani e Babakhani (2012) a integração de redes neurais com o interpolador RBF apresenta resultados satisfatórios no cálculo de infiltração de barragens de terra.

Define-se aprendizagem no contexto de RNA como o processo pelo qual os parâmetros livres de uma RNA são adaptados através de um processo de estimulação pelo ambiente no qual a rede está inserida.

O tipo de aprendizagem é determinado pela maneira pela qual a modificação dos parâmetros ocorre (HAYKIN, 2001).

Segundo Tso e Mater (2009), para realização do aprendizado (treinamento), o número dos neurônios é igual ao número de vetores de características para entrada. Os neurônios da camada de saída têm que competir com os outros neurônios para haver interação entre os padrões de entrada. O resultado é a conexão dos pesos com o neurônio vencedor e os pesos de seus vizinhos são ajustados simultaneamente.

Arquitetura da rede

A maneira pela qual os neurônios de uma rede neural estão estruturados está intimamente ligada com o algoritmo de aprendizagem usado para treinar a rede. Em geral são identificadas duas classes de arquiteturas de rede fundamentalmente diferentes (HAYKIN, 2001) explicitadas nos itens a e b da figura 1.

Em uma rede neural, os neurônios estão organizados na forma de camadas. Na forma mais simples de uma rede de camadas (figura 1 a), tem-se uma camada de entrada de nós de entrada que se projeta sobre uma camada de saída de neurônios (nós computacionais), entretanto a recíproca não é verdadeira. Esta rede é chamada de rede de camada única, sendo que a designação “camada única” se refere à camada de saída de nós computacionais (neurônios).

Em redes com múltiplas camadas, há uma ou mais camadas ocultas, cujos nós computacionais são chamados correspondentemente de neurônios ocultos ou unidades ocultas. A habilidade dos neurônios ocultos é particularmente valiosa quando o tamanho da camada de entrada é grande. Os nós (neurônios) de entrada, como mostrado na figura 1-b, da camada de entrada da rede fornecem os respectivos elementos do padrão de ativação (vetor de entrada), que constituem os sinais de entrada aplicados aos neurônios (nós computacionais) na segunda camada.




Figura 1. (a) Rede de camada única. (b) Rede de múltiplas camadas.

Além do aprendizado e, portanto de treinamento dos dados de entrada para uma determinada saída da rede, ainda necessita-se das funções de ativação e transferência, para que os neurônios (nós) sejam ativados ou não e, transferidos para novas camadas e finalmente para a saída.

Função de ativação e função de transferência

A função de ativação antecede a função de transferência, e tem por atribuição, repassar o sinal para a saída do neurônio. É uma função de ordem interna, cuja atribuição é fazer acontecer um nível de ativação dentro do próprio neurônio, ou seja, é uma decisão tomada pelo neurônio sobre o que fazer com o valor resultante do somatório das entradas ponderadas (TAFNER et al, 1995).

A função de transferência pode ter muitas formas e métodos, podendo ser simples ou complexa. Esta função é que define e que envia para fora do neurônio o valor passado pela função de ativação (TAFNER et al, 1995).

Materiais e métodos

Área de estudo

A área de estudo dessa pesquisa, denominada Fazenda Escola Capão-da-Onça (FESCON) é administrada pela Universidade Estadual de Ponta Grossa (UEPG), no Município de Ponta Grossa,

PR, latitude 25° 05' 35,7"S e longitude 50° 03' 19"W, com altitude em média de 1041 metros (FERREIRA et al. 2010 apud ORLOVSKI, 2013). A FESCON divide-se em duas áreas: experimental, onde fica a sede administrativa e outra de produção comercial com área de 2.181.166,29 m², o que equivale a 218,11 hectares, cuja localização pode ser observada na figura 2.

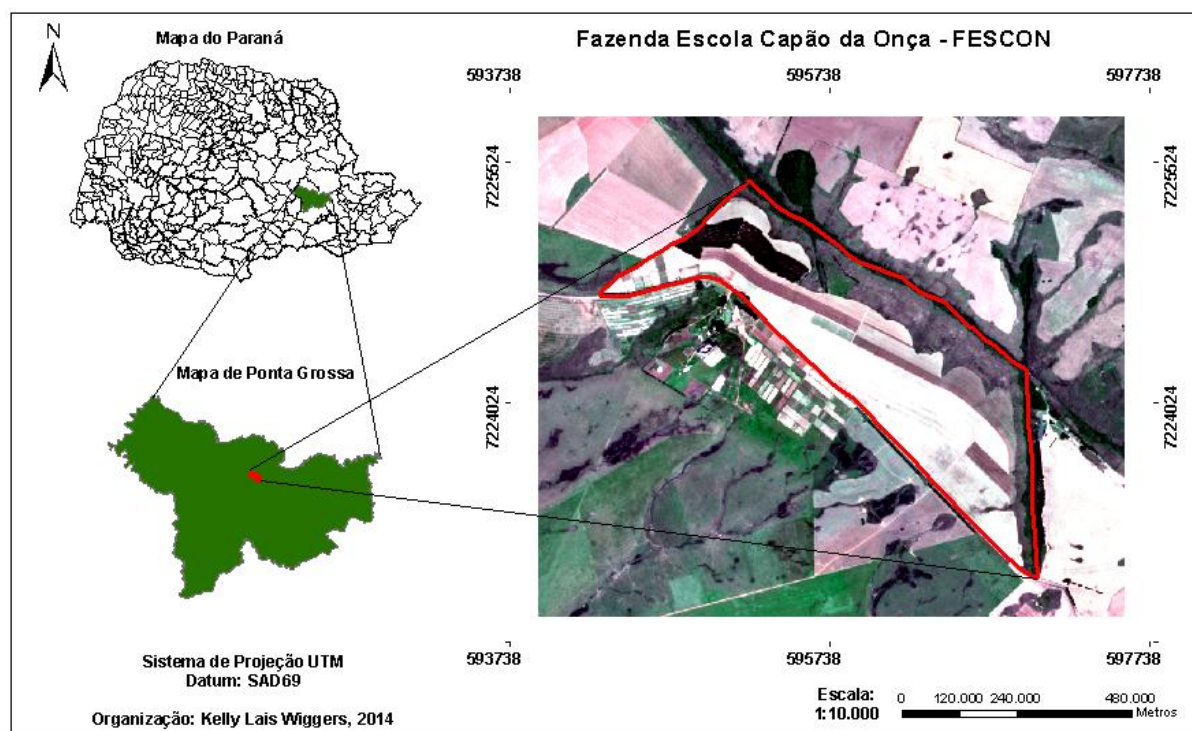


Figura 2. Localização da FESCON.

Na figura 3 apresenta-se o cartograma do relevo (a) e declividade (b), (c) surface e (d) wireframe da área de estudo, os quais são de importância em se tratando de estudos de textura de solos. A partir do vetor, apresentado no cartograma de relevo (hipsometria), foi interpolado e gerada a grade regular com espaçamento de 30 x 30 metros. Sobre esta grade foi realizado o modo de apresentação wireframe e surface, com a possibilidade da sobreposição (overlay) do vetor da área de estudo bem como da ortoimagem. Ambos estão posicionados com o ângulo de 318° em leste-oeste e 42° em norte-sul.

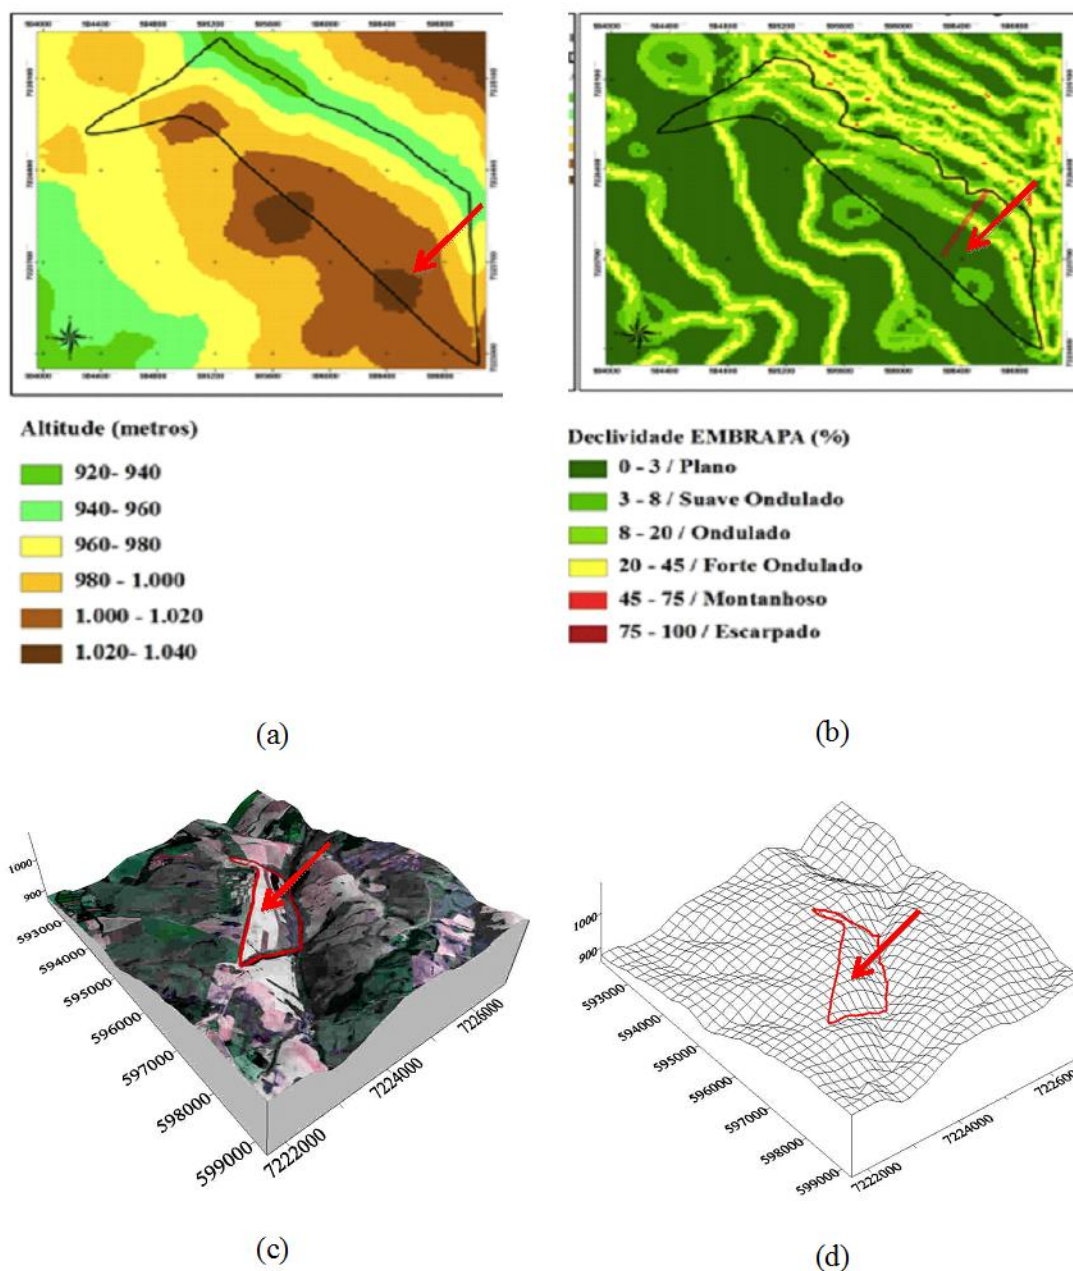


Figura 3. Cartograma de relevo (a), declividade (b), surface (c) e wireframe (d) da FESCON.

A figura 3 (a) representa as variações de altitude sendo a menor altitude em torno de 920 metros e a maior com 1040 metros, destaca-se aqui que o contorno preto corresponde a área de estudo e nota-se que a maior área encontra-se na altitude 980 a 1020 metros. A figura 3 (b) exibe as classes de declive que variam de 0-3% plano a 75-100% escarpado. Na área em questão as classes predominantes de declive são a plana, seguida da suave ondulada, ondulada e com menor representatividade a classe

forte ondulada. Realizando-se uma análise visual, e na sobreposição do surface e wireframe, figuras 3 (c) e (d) respectivamente, nota-se que nos locais de maior altitude tem-se as menores declividades.

Desenvolvimento do trabalho

A figura 4 representa uma visão geral das etapas de desenvolvimento do trabalho. Os dados de entrada, sendo areia, silte e argila foram disponibilizados por Orlovski (2013), quando da sua dissertação e cedidos pelo Programa de Pós Graduação em Computação aplicada da UEPG para este estudo. Antes do treinamento destes vetores (areia, silte e argila), fez-se necessário separá-los entre dados de treinamento e de testes mediante scripts desenvolvido no software Matlab. Neste aplicativo, aplicou-se a RNA escolhida, e para finalização, a interpolação dos dados originais com o resultado da saída da RNA, para posterior análise dos resultados encontrados.




Figura 4. Diagrama de blocos correspondente às etapas de desenvolvimento.

A figura 5 é um exemplo de vetores de entrada (argila) para treinamento da RNA. Todos seguem o mesmo padrão para areia, silte e argila, compondo-se das coordenadas X e Y e os respectivos atributos

de amostra para cada ponto utilizado. Totaliza-se 225 vetores com 4 posições cada. Destaca-se que a unidade de medida da areia, silte e argila é g/kg, e as coordenadas estão em metros.

Ponto	Coordenada X	Coordenada Y	argila
1	595991,138688	7223970,849100	455,07
2	596009,493045	7223961,614070	445,54
3	596027,736667	7223952,528990	336,95

Figura 5. Exemplo de vetores de entrada para treinamento da RNA presente na base de dados.

Após a definição das entradas (vetores de atributos de granulometria dos solos georreferenciados), foi escolhida a RNA e o algoritmo de treinamento. O algoritmo Backpropagation (BP) tem como objetivo encontrar na superfície de erro um mínimo global, ou seja, encontrar valores para os pesos sinápticos que minimizem o erro da rede. O BP utiliza pares de entrada e saída que ajustam os pesos da rede (HAYKIN, 1999), é uma rede neural artificial supervisionada a qual consiste na retropropagação dos erros em cada iteração. O Resilientbackpropagation (Rprop) é uma versão mais rápida do BP, ele trabalha com variação de sinal com o objetivo de reduzir rapidamente o erro de aprendizado (BRAUN e RIEDMILLER, 1993).

O software Matlab possui toolboxes específicas para o uso de RNA, estes apresentam funções: de inicialização da rede, transferência e ativação e ainda é responsável em criar a arquitetura de uma rede, com neurônios em camadas. O usuário precisa otimizar entradas (amostras de treinamento e de generalização - simulação) e saídas bem como definir o número de camadas, escolher as funções devido a complexidade dos vetores a serem treinados, ou seja do problema em questão.

Na figura 6 é possível verificar a estrutura da RNA implementada.

`net=newff(0 1;0 1)[4,30,1]('logsig','logsig','purelin')('trainrp');`

A B C D E

Figura 6. Exemplo de definição da RNA implementada.

A função newff (ponto A) é responsável pela criação de uma rede neural do tipo Backpropagation, os valores do ponto B identificam o limite dos vetores de entrada que serão aplicados a rede neural, o ponto C identifica o número de neurônios que cada camada da rede neural irá possuir, ou seja, quatro neurônios na primeira camada – os quais correspondem aos vetores de entrada, trinta neurônios na segunda e uma única saída, no ponto D aplica a função de transferência em cada camada onde é definido o tipo de saída correspondente ao que se deseja na saída do neurônio e, no ponto E é onde se define o algoritmo de treinamento que a rede irá utilizar. O algoritmo que apresentou maior rapidez e melhores resultados foi o Resilient Backpropagation.

Treinamento e configuração da rede neural

As amostras utilizadas para o treinamento da RNA foram de 50% do total de dados originais. Na figura 7, tem-se o script para coleta das amostras de treinamento, num total de 75 amostras. Ou seja, a planilha de dados é carregada, definindo-se o tamanho da matriz de treinamento. Todos os dados são separados em três arquivos com coordenadas x, y e um atributo (areia, silte e argila), e a cada duas amostras uma é coletada pra o treinamento.

```
[linhas, columnas] = tamanho(Matriz);
dados = linhas/2;

for i=1:dados
    Entrada(i,1) = Matriz(contador, 1);
    Entrada(i,2) = Matriz(contador, 2);
    Entrada(i,3) = Matriz(contador, 3);
    coordenadas(i,1) = Matriz(contador,1);
    coordenadas(i,2) = Matriz(contador,2);
    contador = contador + 2;
end
```

Figura 7. Escolha de amostras para treinamento.

Os dados de areia, silte e argila coletados no campo da FESCON – UEPG, foram organizados mediante o processamento do script exibido na figura 7. Após isso, são treinados na RNA da figura 6 e é gerada uma saída para cada uma das entradas (areia, silte, argila). Desta forma, arquivos de saída dos dados foram salvos e nomeados conforme o tipo de amostra, para futura plotagem no software Surfer 9. A figura 8 demonstra de forma ilustrativa como é formada a RNA implementada no software

Matlab. A camada de entrada corresponde às posições de um vetor de entrada, composta de rótulo, coordenadas X e Y, areia, silte ou argila. Cada um destes nós (neurônios de entrada) é ligado aos neurônios das camadas intermediárias, e esta ligação contém os pesos iniciais, ajustados no decorrer do treinamento.




Figura 8. Arquitetura da RNA implementada.

RESULTADOS E DISCUSSÕES

Nesta seção os resultados das interpolações são apresentados, na forma de Blocos Diagrama (wireframe) e Mapas de Curvas de Contorno, ambos gerados no programa Surfer 9, referentes as interpolações de areia, argila e silte. Destaca-se que as interpolações foram mediante a técnica RBF implementada no programa citado e por meio do processamento no MatLab a RNA, sendo esta última especializada no programa Surfer 9 para as comparações a seguir. Ainda exibe-se os resultados das diferenças das grades interpoladas dos atributos mencionados na forma de gráfico.

A figura 9 apresenta o resultado na forma de bloco diagrama da interpolação do atributo areia mediante RBF (a) e com a RNA (b), respectivamente. Ambas as representações possuem giros de 310 graus em relação ao norte e de 45 graus em relação ao horizonte. As coordenadas estão no sistema UTM; no eixo x têm-se as abcissas, no eixo y são as coordenadas Norte e no eixo Z o atributo (areia).




Figura 9. Bloco diagrama representando a areia, utilizando originais com interpolador RBF (a) e com RNA (b).

A figura 10 (a e b) apresenta a mesma interpolação do atributo areia na forma de curvas de contorno, aqui também destaca-se as diferenças ocorridas destacadas em forma de eclipses, entre as coordenadas 596.170m E & 7.223.825m N e 596.305m E & 7.223.920m N e também entre as coordenadas 596.360m E & 7.223.745m N e 596.455m E e 7.223.825m N, mostrando os locais onde a RNA suavizou mais as superfície que o interpolador spline RBF.

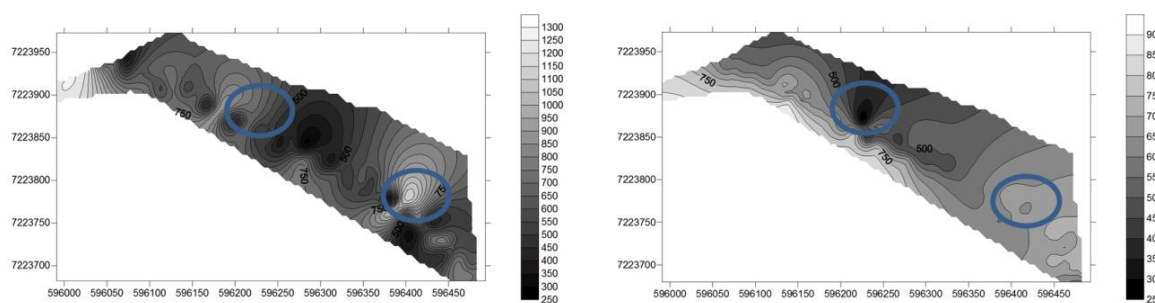


Figura 10. Mapa de contornos com dados de areia, utilizando originais com interpolador RBF (a) e com RNA (b).

Como análise destes resultados, pode-se considerar o gráfico 1 da figura 11. As maiores variações, entre as interpolações RBF versus RNA, foram entre as coordenadas (x) 50 e 70 e atributos (y) 600 a 650 g.Kg-1 de areia. O eixo “Coordenadas” diz respeito aos pontos x e y do local onde foram coletadas as 150 amostras de solo, e o eixo “Areia” diz respeito ao valor do atributo que foi coletado. Nota-se em todas as representações que a RNA sempre suavizou mais quando da interpolação, fatos estes destacados no gráfico 1 da figura 11 com quatro (4) elipses. A tabela do Anexo 1 apresenta os E

e N exatos, das 150 Coordenadas apresentadas no gráfico 1 da figura 11. Desta forma é possível verificar exatamente as coordenadas E e N, previamente grifadas, de onde os valores foram suavizados pela RNA em comparação com a técnica RBF.




Figura 11. Comparação entre dados de areia RBF (originais) e treinados com RNA.

A figura 12 (a) mostra o resultado na forma de superfície da interpolação da argila mediante RBF e (b) com a RNA. Ambas as representações possuem giros de 310 graus em relação ao norte e de 45 graus em relação ao horizonte. As coordenadas estão no sistema UTM. No eixo x têm-se as abscissas. No eixo y são as coordenadas Norte e no eixo Z o atributo (argila).

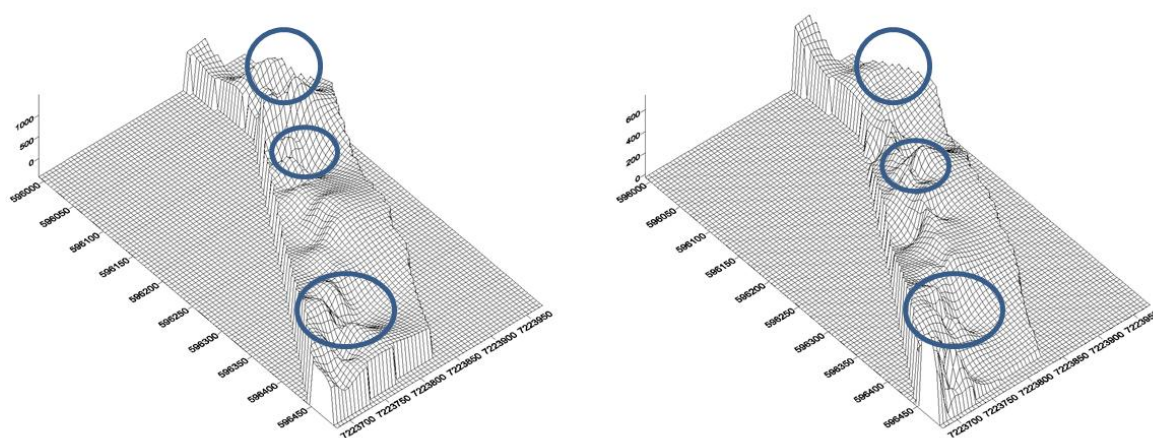


Figura 12. Bloco Diagrama representando a argila, utilizando originais com interpolador RBF (a) e com RNA (b).

A figura 13 (a e b) apresenta a mesma interpolação do atributo argila na forma de curvas de contorno, aqui também destaca-se as diferenças ocorridas destacadas em forma de eclipses, entre as coordenadas 596160 E & 7223860 N e 596249 E & 7223942 N, e também entre as coordenadas 596360 E & 7223750 N e 596456 E & 7223810 N mostrando os locais onde a RNA suavizou mais a superfície que o interpolador spline - RBF.




Figura 13. Mapa de contornos com dados de argila, utilizando originais com interpolador RBF (a) e com RNA (b).

Como análise destes resultados, é possível ponderar no gráfico 2 da figura 14, que as maiores variações foram com coordenadas entre 40 e 70 e atributos 600 a 650. Assim como ocorreu com a areia, nota-se em todas as representações que a RNA quando interpolou os dados de argila em relação ao RBF, suavizou mais a superfície, com exceção da área destaca em vermelho, no gráfico 2 da figura 12 e destacados com as quatro elipses e um retângulo em vermelho. Na tabela do Anexo 1 é possível verificar as coordenadas E e N exatas onde os valores foram suavizados pela RNA.




Figura 14. Comparação entre dados de argila RBF e treinados com RNA.

A figura 15 (a) mostra o resultado na forma de superfície da interpolação da silte mediante RBF e (b) com a RNA. Ambas as representações possuem um giro de 310 graus em relação ao norte e um giro de 45 graus em relação ao horizonte. As coordenadas estão no sistema UTM e no eixo x têm-se as abscissas. No eixo y são as coordenadas Norte e no eixo Z o atributo (silte).

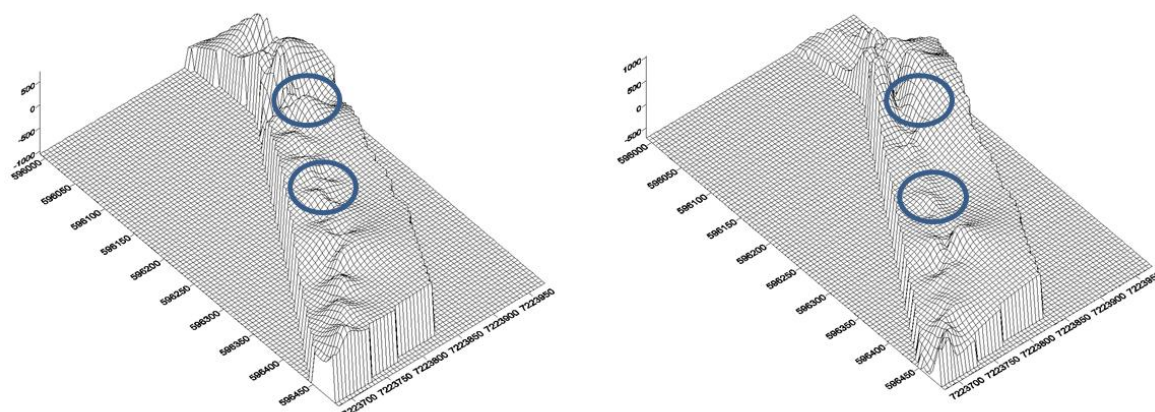


Figura 15. Bloco Diagrama representando o silte, utilizando originais com interpolador RBF (a) e com RNA (b).

A figura 16 (a e b) apresenta a mesma interpolação do atributo silte na forma de curvas de contorno, aqui também destaca-se as diferenças ocorridas destacadas em forma de eclipses, entre as coordenadas 596110 E & 7223850 N e 596210 E & 7223930 N, e também entre as coordenadas 596325 E & 7223730 N e 596415 E & 7223810 N, mostrando os locais onde a RNA suavizou mais a superfície que o interpolador spline – RBF.

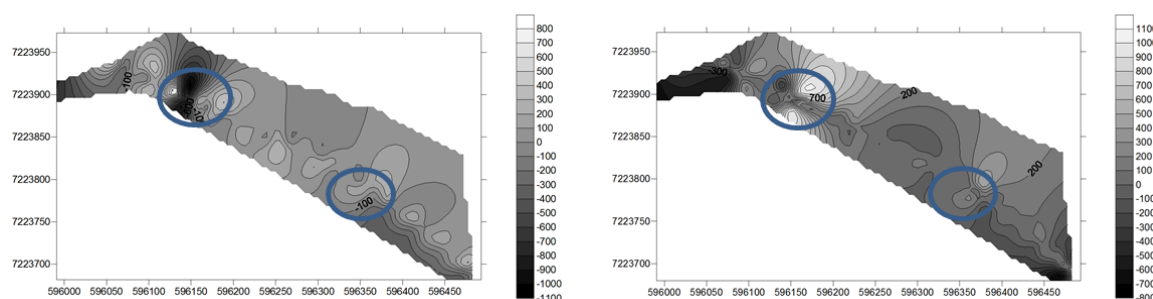


Figura 16. Mapa de contornos com dados de silte, utilizando originais com interpolador RBF (a) e com RNA (b).

Como análise destes resultados, é possível analisar no gráfico 3 da figura 17, que ocorreram muitas variações dos dados do interpolador comparado com a RNA. Com a areia e com a argila nota-se em

todas as representações da RNA quando interpolou os dados em relação ao RBF, sempre suavizou mais a superfície, entretanto neste gráfico 3 da figura 17 a variação dos dados é mais abrupta que os demais já exibidos nas figuras, 13 e 15 e, na primeira elipse a RNA não suavizou os dados como nos demais. Na tabela do Anexo 1 é possível verificar as coordenadas E e N exatas onde os valores foram suavizados pela RNA.




Figura 17. Comparação entre dados de silte originais e treinados com RNA.

Conclusão

Os dados georreferenciados, coletados da FESCON são bastante representativos e importantes para a espacialização granulométrica de solos, sendo possível realizar a interpolação utilizando o RBF e treinamento supervisionado por RNA. Desta forma, os resultados demonstraram-se significativos, permitindo análise das representações das superfícies a partir da RNA e RBF. E culminando na reflexão da importância do método de interpolação e como este pode alterar os dados quando da espacialização.

Os dados de areia foram os mais suavizados quando da utilização da RNA em contrapartida com a RBF. Nota-se principalmente a suavização dos dados por parte da RNA nas coordenadas N entre 596.200 e 596.400m e E 7.223.750 e 7.223.900m. Analisando-se a figura 10, MDT e declividade,

esta é a porção sudeste (SE) nas altitudes de 960m a 1020m e com as declividades plana e suave ondulada.

Os dados de argila foram suavizados quando da utilização da RNA em contrapartida com a RBF, porém não tanto quanto os dados de areia. Foi possível verificar a suavização dos dados com a RNA nas coordenadas N entre 596.150 e 596300m e E 7.223.750 e 7.223.900m e analisando-se a figura 13, MDT e declividade, esta é a porção sudeste(SE) nas altitudes de 940m a 1020m e com as declividades plana e suave ondulada.

Os dados de silte também foram suavizados pela RNA em contrapartida com o RBF, entretanto não tanto quanto os dados de areia e argila. Verificou-se a suavização dos dados com a RNA nas coordenadas N entre 596.150 e 596.250m e E 7.223.800 e 7.223.900m e analisando-se a figura 16, MDT e declividade, esta é a porção sudeste(SE) nas altitudes de 940m a 1020m e com as declividades plana e suave ondulada.

Agradecimentos

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pelo apoio financeiro. Ao Programa de Pós-Graduação em Computação Aplicada do Departamento de Informática da UEPG pela disponibilidade do uso do software Matlab 9. À Mestre Regiane Orlovski pelo material disponibilizado para estudo. Ao laboratório de Geotecnologias do Departamento de Geociências da UEPG pela disponibilidade de uso das licenças dos softwares Surfer 9, ArcGis 9.

REFERÊNCIAS

ANTUNIASSI, U.; BAILO, F.; SHARP, T. Agricultura de Precisão e aplicação localizada de insumos. IN. **VI Congresso Brasileiro de Algodão**, 2007.

ASSAD, E.D.; SANO, E.E. **Sistemas de informações geográficas (Aplicações na Agricultura)**. 2.ed. Brasília, DF: SPI/EMBRAPA-CPAC, 1998. p. 434.

BRADY, N. C; WEIL, R. R. **The nature and properties of soils**. 14th ed. New Jersey: Prentice Hall, 2008.

- BURROUGH, P.A. **Principals of Geographical Information Systems for Land Resources Assessment**. Oxford, Clarendon Press, 1986. p. 194.
- CHEN, H.; LEOU, J. Saliency-directed color image interpolation using artificial neural network and particle swarm optimization. **Journal of Visual Communication and Image Representation**, v 23, p. 343–358, 2012.
- GORGENS E., B. et al. Estimate of tree volume using artificial neural nets. **Revista Árvore**, Viçosa, v. 33, n. 6, 2009.
- HAYKIN, S., **Redes Neurais: Princípios e Prática**. 2 ed. Editora Prentice Hall, Inc, 1999.
- HAYKIN, S. **Redes Neurais: Princípios e Prática**. 2 ed. Porto Alegre: Bookman, 2001.
- IBGE - Instituto Brasileiro De Geografia E Estatística. **Manual Manual Técnico de Pedologia**. Rio de Janeiro: IBGE, 2 ed 2007.
- MAPA. Ministério da Agricultura, Pecuária e Abastecimento. Agricultura de precisão / Ministério da Agricultura, Pecuária e Abastecimento. **Secretaria de Desenvolvimento Agropecuário e Cooperativismo**. Brasília : Mapa/ACS, p. 36, 2011.
- MAZZINI, P. L. F.; Schettini, C. A. F. Avaliação de metodologias de interpolação espacial aplicadas a dados hidrográficos costeiros quase- sinóticos. **Braz. J. Aquat. Sci. Technol.**, 2009.
- MOLIN, J. P.; Agricultura de precisão. Parte 1: O que é e estado da arte em sensoriamento. **Engenharia Agrícola**, v. 17, f. 2, p. 97-107, 1997.
- NOURANI, V.; BABAKHANI, A.; Integration of Artificial Neural Networks with Radial Basis Function Interpolation in Earthfill Dam Seepage Modeling. **Journal of Computing In Civil Engineering**, v. 27, p 183-195, 2012.
- ORLOVSKI, R. Avaliação de espaçamentos das coletas de solo para a modelagem de granulometria com aplicação na agricultura de precisão. **(Dissertação) Universidade Estadual de Ponta Grossa**, 2013.
- PAIVA NETO, J. E. de. A "fração argila" dos solos do Estado de São Paulo e seu estudo roentgenográfico. **Bragantia[online]**. vol.2, n.10, p. 355-432, 1942.
- REICHARDT, K.; TIMM, L. C. **Solo, planta e atmosfera: conceito, processo e aplicações**. Barueri: Manóle, 2004.
- REZENDE, S. O. (Org.). **Sistemas Inteligentes: fundamentos e aplicações**. São Paulo: Monole, 2005.
- RIEDMILLER, M.; BRAUN, H. A direct adaptive method for faster back propagation learning: The RPROP algorithm. **Proceedings of the IEEE International Conference on Neural Networks**, 1993.
- TAFNER, M. S.; et al. **Redes Neurais Artificiais: Introdução e Princípios de Neurocomputação**. Blumenau: Editora da FURB, 2005.
- TSO, B.; MATHER, P. **Classification methods for remotely sensed data**. CRC Press: Taylor & Francis Group, 2 ed. 356p, 2009.

Anexos

Point	Coordinate X	Coordinate Y	Sand	Silt	Clay
1	595991,138688	7223970,849100	494,02	50,91	455,07
2	596009,493045	7223961,614070	493,35	61,11	445,54
3	596027,736667	7223952,528990	618,23	44,83	336,95
4	596046,069386	7223944,244620	595,2	44,33	360,47
5	596064,327566	7223934,886830	581,16	47,97	370,87

6	596081,459233	7223926,663790	635,59	51,32	313,09
7	596100,069796	7223916,914000	652,35	47,79	299,87
8	596117,939104	7223908,391010	658,51	51,32	290,18
9	596136,585910	7223899,695770	658,8	53,22	287,98
10	596154,601640	7223890,968960	664,88	57,29	277,83
11	596172,152052	7223882,875130	651,91	64,6	283,49

12	596190,162351	7223874,059720	643,12	64,37	292,52
13	596208,328830	7223865,309010	587,1	70,77	342,13
14	596226,426886	7223856,828550	514,67	76,94	408,39
15	596244,615526	7223848,762720	486,15	80,44	433,41
16	596262,529447	7223840,393640	455,11	80	464,89
17	596280,671896	7223832,496350	495,69	80,21	424,1
18	596298,466150	7223823,174120	477,2	68,12	454,68
19	596316,677279	7223814,497390	492,92	74,3	432,79
20	596334,058773	7223805,517650	532,81	61,58	405,61
21	596351,917860	7223795,272310	570,93	66,53	362,54
22	596368,954748	7223784,746060	627,36	52,21	320,43
23	596384,716292	7223772,327680	658,13	33,66	308,21
24	596400,700851	7223759,800330	661,07	40,42	298,51
25	596415,757505	7223747,255230	644,76	38,82	316,43
26	596431,199907	7223734,044760	698,31	47,78	253,91
27	596446,118443	7223720,792440	644,06	48,56	307,39
28	596461,006863	7223707,484340	658,83	52,04	289,13
29	596475,928229	7223693,808980	721,08	34,25	244,67
30	596490,025843	7223680,306170	604,63	66,02	329,35
31	595991,816505	7223971,832120	469	102	430
32	595992,333350	7223972,709820	460	83	456
33	595992,670352	7223972,632390	459	84	457
34	595992,250081	7223972,222210	454	88	458
35	596010,194471	7223963,760970	474	95	431
36	596010,547005	7223964,576160	475	95	431
37	596011,036388	7223964,140190	459	84	457
38	596010,775203	7223963,170240	461	82	457
39	596028,564726	7223954,280620	553	66	380
40	596028,893172	7223955,095970	554	67	379
41	596029,261860	7223955,023240	549	73	378
42	596028,781573	7223954,245560	547	74	380
43	596046,998865	7223945,084350	609	61	330
44	596047,335977	7223946,016230	623	63	314
45	596047,723955	7223945,739400	602	45	353
46	596047,203484	7223944,943860	604	43	353
47	596064,699862	7223936,557690	563	93	344
48	596064,990278	7223937,382230	544	27	429
49	596065,271742	7223937,016320	545	76	380
50	596064,750051	7223936,326000	554	66	380
51	596081,699733	7223928,513380	584	37	379
52	596082,088096	7223929,403680	587	33	379
53	596082,659241	7223928,923760	592	54	354
54	596082,276153	7223927,947290	589	82	329
55	596100,434858	7223918,710430	644	31	326
56	596100,723438	7223920,068710	641	59	301
57	596101,204131	7223919,989960	641	57	302
58	596100,829235	7223919,102940	640	31	329
59	596118,251613	7223910,480660	641	57	302
60	596118,552136	7223911,109480	615	82	302
61	596119,008699	7223910,747260	652	71	277
62	596118,478897	7223909,939790	645	52	303
63	596137,335147	7223901,390730	642	56	302
64	596137,303277	7223902,074810	631	42	328
65	596137,720937	7223901,836530	636	12	352
66	596137,633818	7223900,923190	618	29	353
67	596155,293068	7223892,371170	648	26	327
68	596155,621444	7223893,175750	648	50	302
69	596155,946573	7223892,884900	642	56	302
70	596155,684639	7223892,484990	654	44	302
71	596172,418906	7223883,813350	635	63	302
72	596172,812587	7223884,662700	642	81	277
73	596173,270075	7223884,511190	648	88	264
74	596172,971513	7223883,684250	635	89	276
75	596190,588749	7223875,297670	624	74	302
76	596190,966491	7223876,111140	632	91	277
77	596191,568194	7223875,992760	627	96	277
78	596191,197320	7223875,358590	632	66	302
79	596208,637660	7223867,113830	571	50	379
80	596209,022042	7223868,034300	586	36	378
81	596209,466592	7223867,915180	581	41	378
82	596209,216389	7223866,677520	576	71	354
83	596226,967624	7223858,668330	509	86	405
84	596227,256352	7223859,728530	508	86	406
85	596227,642630	7223859,291120	510	84	406
86	596227,431972	7223858,457100	512	59	429
87	596245,255267	7223850,341550	488	80	432
88	596245,719276	7223850,875700	485	81	434

89	596246,035085	7223850,693500	478	92	430
90	596245,844100	7223850,027300	481	62	457
91	596263,153342	7223841,830770	462	79	459
92	596263,311922	7223842,549180	467	54	480
93	596263,794139	7223842,329820	465	55	480
94	596263,549336	7223841,579410	482	64	455
95	596281,255965	7223833,292060	470	88	442
96	596281,542286	7223833,693950	473	94	433
97	596282,068593	7223833,411210	467	89	444
98	596281,722865	7223832,887300	470	75	455
99	596299,505463	7223824,452350	471	98	431
100	596299,739394	7223825,130550	468	74	459
101	596300,306991	7223825,101620	463	78	460
102	596300,042131	7223824,605140	464	79	457
103	596317,422297	7223815,870290	475	93	432
104	596318,053238	7223816,599520	484	85	431
105	596318,489518	7223816,420480	477	91	432
106	596318,283691	7223815,755300	475	92	433
107	596334,874571	7223806,877740	515	77	408
108	596335,202745	7223807,810910	515	80	405
109	596335,717990	7223807,548560	522	71	407
110	596335,263284	7223807,142010	508	85	407
111	596352,827240	7223796,912610	573	49	378
112	596353,426629	7223797,537160	552	69	380
113	596353,916381	7223797,393420	563	58	380
114	596353,361784	7223796,567050	565	57	378
115	596370,024387	7223785,796420	609	37	354
116	596370,403162	7223786,556660	611	36	353
117	596370,930515	7223786,303440	612	59	328
118	596370,358189	7223785,505200	620	76	304
119	596385,773454	7223773,910930	624	73	302
120	596386,167846	7223774,700900	650	47	303
121	596386,565511	7223774,369540	646	76	277
122	596386,172374	7223773,717380	628	69	304
123	596401,711078	7223761,242720	654	68	277
124	596402,162429	7223762,006440	666	57	277
125	596402,576334	7223761,713730	677	70	253
126	596402,111247	7223760,433910	637	84	279
127	596416,917939	7223748,271110	661	62	277
128	596417,601065	7223749,170080	672	50	278
129	596417,943705	7223748,821580	655	67	277
130	596417,668328	7223748,581120	675	46	278
131	596432,551596	7223735,565940	689	84	227
132	596433,175269	7223736,257380	689	85	226
133	596433,518088	7223735,775980	687	87	226
134	596433,079039	7223734,969720	687	87	226
135	596447,573215	7223722,076020	669	81	251
136	596448,135865	7223722,654680	675	99	226
137	596448,631740	7223722,268490	664	86	250
138	596447,921568	7223721,426930	650	99	251
139	596462,243424	7223709,084470	724	75	201
140	596462,758842	7223709,520110	714	86	200
141	596463,391812	7223709,308900	719	81	200
142	596462,675948	7223708,415090	724	77	200
143	596477,095303	7223695,010920	705	95	200
144	596478,015509	7223695,647030	701	99	200
145	596478,508302	7223695,181800	703	96	201
146	596477,562243	7223694,613240	690	83	226
147	596491,587861	7223681,742490	632	91	277
148	596492,230087	7223682,324280	637	87	276
149	596492,779815	7223681,948470	633	87	279
150	596492,106263	7223681,531480	623	96	281

Anexo 1. Valores das coordenadas X, Y e atributos Areia, Argila e Silte.