

## Modelagem de Objetos e Algoritmo de Distribuição de Sensores para uma Ferramenta Computacional Visando Aplicações em Agricultura de Precisão

### *Modeling of Object and Algorithm of Sensor Distribution for a Computational Tool Aiming for Applications in Precision Agriculture*

Marcos Alexandre Fernandes Ferronato<sup>1</sup>, Simone Vasconcelos Silva<sup>2</sup>, Antônio José da Silva Neto<sup>3</sup>

#### RESUMO

Este trabalho tem como objetivo apresentar os resultados obtidos a partir da modelagem de objetos e do algoritmo utilizados como base para o desenvolvimento de uma ferramenta computacional para distribuição maximizada de sensores de aquisição por proximidade de atributos de solos através da condutividade elétrica. Tal ferramenta proporciona um suporte à decisão para agricultura de precisão. O trabalho consiste no fluxo de atividades que vai desde a modelagem dos objetos necessários para o armazenamento das informações das unidades de agronegócio até os resultados obtidos pelo uso da ferramenta computacional que implementou estes objetos e o algoritmo de otimização denominado Cobertura por Busca Binária de Variação Significativa (CBBVS). Por meio da ferramenta, baseada em CBBVS, foram executados testes piloto e trabalho de campo da distribuição dos sensores para maior cobertura, e com isso foi possível demonstrar que o uso de ferramentas computacionais pode melhorar a aquisição e o nível das informações, contribuindo assim para suporte à gestão nas unidades de agronegócio e criando condições para a melhoria da sustentabilidade e da rentabilidade com a utilização da agricultura de precisão.

**Palavras-chave:** Modelagem de Objetos, Ferramenta Computacional, Sensoriamento, Agricultura de Precisão.

#### ABSTRACT

This work aims to present the results obtained from object modeling and the algorithm used as the basis for the development of a computational tool for the maximized distribution of proximity sensors of attributes of soils through the electrical conductivity. Such a tool provides decision support for precision farming. The work consists of the activity flow that goes from the modeling of the objects necessary for the storage of the information of the agribusiness units to the results obtained by the use of the computational tool that implemented these objects and the optimization algorithm called Binary Search Coverage of Significant Variation (CBBVS). Through the tool, based on CBBVS, pilot tests and field work of the sensor distribution were performed for greater coverage, and with this it was possible to demonstrate that the use of computational tools can improve the acquisition and level of information, thus contributing to support management in the agribusiness units and creating conditions for the improvement of sustainability and profitability with the use of precision agriculture.

**Keywords:** Modeling of Objects, Computational Tool, Sensing, Precision Agriculture.

<sup>1</sup> Mestre. Instituto Federal Fluminense, SAEG.

E-mail:

ferronato.marcos@gmail.com

<sup>2</sup> Ds.C Instituto Federal Fluminense, SAEG.

E-mail: simonevs@iff.edu.br

<sup>3</sup> PhD Universidade do Estado do Rio de Janeiro, Instituto Politécnico.

E-mail: ajsneto@iprj.uerj.br

## 1. INTRODUÇÃO

Srinovska et al. (2014) afirmam que inovação e automação no agronegócio têm por objetivo reforçar a competitividade da agricultura do setor e contribuir para a proteção do ambiente e para apoiar o emprego e o crescimento em áreas rurais. A economia brasileira é fortemente baseada no agronegócio, que representa de forma direta, aproximadamente 27% (R\$ 1,7 trilhões) do PIB brasileiro, que no ano 2016 foi de R\$ 6,3 trilhões. A área de uso efetivo com agronegócio é de 305 milhões de ha, distribuídos em 56 milhões de unidades de agronegócio, fazendo o país ser o maior em área produtiva no mundo (IBGE 2017).

Para Dutta et al. (2014), o último desafio da gestão do agronegócio, seja do ponto de vista ambiental e de sustentabilidade ou do ponto de vista de rentabilidade, está relacionado a sistemas de apoio à decisão. Desta mesma forma, Fountas et al. (2015) afirmam que a introdução de tecnologias de agricultura de precisão para atividades agropecuárias fornece aos gestores do agronegócio a oportunidade de lidar com a variabilidade do dia a dia das lavouras e de gerenciar de forma eficiente uma vasta quantidade de informação disponível.

Agricultura de precisão combina o uso de tecnologias de automação do agronegócio com métodos consolidados de gestão para garantir os melhores resultados. A obtenção de informações em tempo real para monitorar culturas ou fazer previsões de rendimento é um desafio possível de ser vencido, ao se utilizar uma abordagem com modelos de rendimento das culturas em combinação com dados em tempo real (MESAS-CARRASCOSA et al., 2015).

Kone et al. (2015) afirmam que a agricultura de precisão é gerada por um ambiente computacional (hardware e software) para uma gestão do agronegócio com o objetivo de regular mais de perto (em quantidade, espaço e tempo), as necessidades das culturas em pesticidas, fertilizantes e irrigação. Com base nas informações coletadas nas lavouras (por exemplo, temperatura, umidade, fertilizantes e os níveis de pesticidas), pode-se fornecer os insumos necessários (fertilizantes, pesticidas e irrigação) para maximizar a produtividade da cultura, preservando os recursos e protegendo o meio ambiente.

Celinski et al. (2009) propõem o uso de medição condutividade elétrica do solo por meio de multímetro, para através da resistência elétrica do solo estimar de forma bem próxima à realidade os valores de seus atributos físicos.

A otimização na utilização de recursos possibilita a criação de condições para melhoria dos resultados nas organizações, nessa linha, Luus e Jaakola (1973) afirmam que otimizar a utilização de recursos requer o uso de modelos e métodos que sejam rápidos na obtenção de resultados, que sejam confiáveis, e que sejam capazes de encontrar os gargalos e redesenhar aspectos do sistema para maximizar a função objetivo relacionada ao problema proposto.

Rabello et al. (2014) afirmam que a Condutividade Elétrica (CE) se mostra bastante eficaz como mecanismo de interpretação dos atributos físicos de solo e que é necessário expandir as pesquisas no sentido de criar sensores de proximidade capazes de medir as menores variações de CE, para possibilitar a interpretação de atributos químicos. A eficiência e eficácia da utilização da medição por proximidade da condutividade elétrica como mecanismo de interpretação do atributo pH do solo foram comprovadas por diversos estudos (BRANDÃO et al., 2017).

O presente artigo tem como objetivo principal apresentar os resultados obtidos por meio da utilização de uma ferramenta computacional desenvolvida através do modelo de objetos e de otimização da distribuição de sensores de aquisição por proximidade de atributos de solos através da condutividade elétrica.

A partir da introdução, o artigo encontra-se estruturado nas seguintes seções: Seção 2 trata dos materiais e métodos aplicados no trabalho, assim como a modelagem dos objetos para os atributos de solo e o algoritmo para a distribuição dos sensores; Seção 3 apresenta os resultados alcançados por este trabalho; e a Seção 4 aborda as considerações finais do trabalho.

## 2. MATERIAIS E MÉTODOS

Nesta seção são apresentados os procedimentos metodológicos que guiaram a pesquisa.

### 2.1 Local e Período de Realização

A Unidade 1 é a unidade de produção agrícola situada no município de Iporã localizado geograficamente no sudoeste do Paraná com latitude 24° 17' 25,74" Sul e longitude 53° 52' 35,57" Oeste, com solo Nitossolo Vermelho, conforme definições do Bloco 1 da Etapa I da metodologia abordada neste trabalho na Seção 2.2.

As atividades dos trabalhos de campo foram executadas no período de nove de fevereiro a dezessete de fevereiro de 2018.

As instituições envolvidas nesta pesquisa foram o Polo de Inovação, credenciado pela Embrapii (Empresa Brasileira de Pesquisa e Inovação Industrial), do Instituto Federal Fluminense (IFFluminense), localizado em Campos dos Goytacazes - RJ e o Instituto Politécnico do Estado do Rio de Janeiro (IPRJ) da Universidade do Estado do Rio de Janeiro (UERJ), localizado em Nova Friburgo – RJ.

## 2.2 Procedimentos Metodológicos

O método MMOADS-FECOMAP propõe a criação e desenvolvimento de um algoritmo de distribuição de sensores com seus respectivos modelos de objetos relacionados e desenvolvimento de ferramenta computacional visando a aplicação em Agricultura de Precisão.

As etapas do desenvolvimento do método estão representadas na Figura 1, a qual o sintetiza de forma gráfica e de acordo com a Figura 1, o método está dividido em sete blocos:

- Bloco 1 – Definições Básicas – representam as etapas de mapeamento dos tipos de solo e culturas a serem tratadas pela pesquisa de acordo com premissas de maior abrangência e produtividade para produtos de tecnologia no agronegócio. Trata também dos atributos de solos e lavouras que mais influenciam nos resultados do agronegócio;
- Bloco 2 – Modelo de Distribuição de Sensores – são as etapas de desenvolvimento do modelo de objetos e algoritmo de distribuição, desenvolvimento do software de integração das informações de sensoriamento, projeto de hardware do sensor de proximidade, definição das unidades de agronegócio para aplicação da pesquisa e montagem do banco de imagem através do uso de drone para distribuição dos sensores;
- Bloco 3 – Execução e Validação do Sensoriamento em Laboratório – contém as etapas referentes a execução e validação dos elementos de sensoriamento em condições de laboratório;
- Bloco 4 – Validação em Laboratório do Modelo de Distribuição – corresponde à validação em laboratório do modelo e dos objetos de distribuição dos sensores;
- Bloco 5 – Validação em Unidade de Testes – é realizada a validação em unidade de testes do protótipo de sensoriamento e seus resultados comparados com a medição tradicional dos atributos de solo e lavoura;

• Bloco 6 – Validação em Unidade Piloto – consiste na validação do modelo de distribuição dos sensores integrado ao sensoriamento dos atributos de solo em unidade piloto;




• Bloco 7 – Trabalho de Campo – é realizado o trabalho de campo nas unidades de agronegócio selecionadas (vide Seção 2.1), utilizando-se o ambiente de distribuição de sensores integrado ao funcionamento dos sensores de atributos de solo.



Figura 1. Fluxograma proposto para método MMOADS-FECOMAP e agrupamento por tipo de atividade. Fonte: Adaptado de Ferronato, Silva e Silva Neto (2018).

Como forma de representar as etapas do fluxo acima que foram ou não executadas por esta pesquisa apresenta-se a Tabela 1 com seus ícones e legendas.

Tabela 1. Legenda do fluxo proposto para metodologia.

ÍCONE	LEGENDA
	Etapas realizadas pelo contrato da NetWord com o Polo de Inovação de Campos dos Goytacazes do IF Fluminense
	Etapas realizadas na pesquisa
	Etapas prevista na metodologia e não realizadas na pesquisa

## 2.3 Objetos e Algoritmo

Os objetos modelados nesse artigo são: tipos de solo, culturas, atributos físicos e químicos de solos mais relevantes, concentração ideal dos atributos físicos e químicos de solo, umidade do solo, temperatura do solo, condutividade elétrica associada aos atributos físicos e químicos do solo. Os passos que definem a modelagem desses objetos são (FERRONATO, SILVA e SILVA NETO, 2018):

- Passo 1 – Identificar todos os tipos de solos do Brasil  $SP_i^r$ , com  $i$  representando cada um dos solos do país,  $i = 1, 2, \dots, N_{sp}^r$ , e com  $r$  representando cada uma das regiões do país,  $r = 1$  a 5.  $N_{sp}$  representa o número total de solos;
- Passo 2 - Identificar todas as culturas desenvolvidas no Brasil  $CP_j^r$ , com  $j$  representando cada uma das culturas do país,  $j = 1, 2, \dots, N_{cp}^r$ , e com  $r$  representando cada uma das regiões do país,  $r = 1$  a 5.  $N_{cp}$  representa o número total de culturas;
- Passo 3 – Neste passo estão representados os atributos físicos de solos mais relevantes  $AFP_l^\sigma$ , com  $l$  representando cada um dos atributos físicos da pesquisa com  $l = 1$  a 3 (Umidade, Temperatura e Densidade), e  $\sigma$  representando cada um dos solos da pesquisa,  $\sigma = 1, 2, \dots, N_{sp}$ ;
- Passo 4 – Neste passo estão representados os atributos químicos de solo mais relevantes  $AQP_m^\sigma$ , com  $m$  representando cada um dos atributos químicos da pesquisa,  $m = 1$  a 4 (N-Nitrogênio, Ca-Cálcio, P-Fósforo e K-Potássio), e  $\sigma$  representando cada um dos solos da pesquisa,  $\sigma = 1, 2, \dots, N_{sp}$ ;
- Passo 5 – Determinar e documentar a concentração ideal dos atributos físicos de solo da pesquisa  $CT(AF_l)_{\sigma}^{\delta}$ , com  $l$  representando cada um dos atributos físicos da pesquisa,  $l = 1$  a 3 (Umidade, Temperatura e Densidade),  $\sigma$  representando cada um dos solos da pesquisa,  $\sigma = 1, 2, \dots, N_{psp}$  e  $\delta$  representando cada uma das culturas da pesquisa,  $\delta =$

$1, 2, \dots, N_{pcp}$ .  $N_{psp}$  representa o número total de solos e  $N_{pcp}$  representa o número total de culturas tratados na pesquisa;

- Passo 6 – Determinar e documentar a concentração ideal dos atributos químicos de solo da pesquisa  $CT(AQ_m)_\sigma^\delta$ , com  $m$  representando cada um dos atributos químicos da pesquisa,  $m = 1$  a 4 (N-Nitrogênio, Ca-Cálcio, P-Fósforo e K-Potássio),  $\sigma$  representando cada um dos solos da pesquisa,  $\sigma = 1, 2, \dots, N_{psp}$  e  $\delta$  representando cada uma das culturas da pesquisa,  $\delta = 1, 2, \dots, N_{pcp}$ ;
- Passo 7 – Representação do valor de umidade do solo  $US_{uSP_\sigma}^{CP_\delta}$ , com  $u$  representando cada um dos sensoriamentos de umidade, com  $u = 1, 2, \dots, N_{su}$ ,  $SP_\sigma$  representando cada um dos solos da pesquisa, com  $SP_\sigma = 1, 2, \dots, N_{psp}$  e  $CP_\delta$  representando cada uma das culturas da pesquisa, com  $CP_\delta = 1, 2, \dots, N_{pcp}$ .  $N_{su}$  representa o número total de medidas de umidade da pesquisa;
- Passo 8 – Representação do valor de temperatura do solo  $TS_{tSP_\sigma}^{CP_\delta}$ , com  $t$  representando cada um dos sensoriamentos de temperatura, com  $t = 1, 2, \dots, N_{st}$ ,  $SP_\sigma$  representando cada um dos solos da pesquisa, com  $SP_\sigma = 1, 2, \dots, N_{psp}$  e  $CP_\delta$  representando cada uma das culturas da pesquisa, com  $CP_\delta = 1, 2, \dots, N_{pcp}$ .  $N_{st}$  representa o número total de medidas de temperatura da pesquisa;
- Passo 9 – Representação do valor de condutividade elétrica do atributo físico  $CEP_{ceSP_\sigma}^{CP_\delta}(f_n, CT^*(AF_l^z)_\sigma^\delta)$ , com  $ce$  representando cada um dos sensoriamentos de condutividade elétrica do solo para os atributos, com  $ce = 1, 2, \dots, N_{sce}$ , onde  $SP_\sigma$  representa cada um dos solos da pesquisa, com  $SP_\sigma = 1, 2, \dots, N_{psp}$ , e  $CP_\delta$  representa cada uma das culturas da pesquisa, com  $CP_\delta = 1, 2, \dots, N_{pcp}$ . O símbolo  $f_n$  representa as frequências relacionadas à concentração do atributo físico  $CT^*(AF_l^z)$ , associada ao índice  $z$  do atributo.  $N_{sce}$  representa o número total de medidas de condutividade elétrica para o atributo físico;
- Passo 10 – Representação do valor de condutividade elétrica dos atributos químicos  $CEP_{ceSP_\sigma}^{CP_\delta}(f_n, CT^*(AQ_m^z)_\sigma^\delta)$ , com  $ce$  representando cada um dos sensoriamentos de condutividade elétrica do solo para os atributos químicos com,  $ce = 1, 2, \dots, N_{sce}$ , onde  $SP_\sigma$  representa cada um dos solos da pesquisa, com  $SP_\sigma = 1, 2, \dots, N_{psp}$  e  $CP_\delta$  representa cada uma das culturas da pesquisa, com  $CP_\delta = 1, 2, \dots, N_{pcp}$ . O símbolo  $f_n$  representa as frequências relacionadas à concentração do atributo químico  $CT^*(AQ_m^z)$ ,

associada ao índice  $z$  do atributo.  $N_{sce}$  representa o número total de medidas de condutividade elétrica para o atributo químico.

Candès (2010) propõe que para otimizar uma extensa área, esta pode ser dividida como elementos de uma matriz, não existindo a necessidade de percorrer todos os elementos, bastando identificar comportamentos semelhantes e percorrer somente os elementos que apresentam variação.


Baseado no método de Candès (2010), este artigo aborda a definição dos objetos para distribuição ótima dos sensores para otimização, denominada Cobertura por Busca Binária de Variação Significativa (CBBVS). Este modelo implementa o conceito de distribuir os sensores somente nas áreas onde houver variação da concentração dos atributos, tanto em relação ao padrão quando em relação aos outros pontos de sensoriamento. Na representação dos objetos necessários para implementação do método CBBVS define-se  $ATS = (\alpha * \beta)$ , com  $ATS$  representando a área total a ser sensoriada,  $\alpha$  representando o comprimento (em metros) da área a ser sensoriada em relação ao eixo  $x$  e  $\beta$  representando a largura (em metros) da área a ser sensoriada em relação ao eixo  $y$  do plano cartesiano. Define-se ainda  $NQ_{ger} = ATS / 10.000$ , com  $NQ_{ger}$  representando o número de quadrantes (1 ha) possíveis de sensoriamento.  $\gamma = NQ_{ger} / (\beta / 1000)$ , com  $\gamma$  representando o índice relativo a cada linha da matriz de quadrantes possíveis de sensoriamento. Define-se o índice relativo como  $\rho = NQ_{ger} / (\alpha / 1000)$ , com  $\rho$  representando o índice relativo a cada coluna da matriz de quadrantes possíveis de sensoriamento.  $MS_{ger}[lim_{\gamma}, col_{\rho}]$  representa a matriz gerada para sensoriamento, com  $\alpha = 1, 2, \dots, C_{base}$ ,  $\beta = 1, 2, \dots, C_{altura}$ ,  $\gamma = 1, 2, \dots, N_{lim}$ ,  $\rho = 1, 2, \dots, N_{col}$  (FERRONATO, SILVA e SILVA NETO, 2018).

O método CBBVS está representado pela Figura 2 e para a implementação dos objetos no sentido de otimizar a distribuição dos sensores foi desenvolvido o pseudocódigo representado no Algoritmo 1. Este modelo de otimização usou como base os conceitos de Luus e Hennessy (1999) com a otimização de pesquisa direta. Estes autores propõem que a otimização seja feita a partir da região de pesquisa determinada de acordo com a extensão das mudanças nas variáveis durante cada uma das iterações (FERRONATO, SILVA e SILVA NETO, 2018).



```
1 Algoritmo de cálculo da distribuição ótima dos sensores de Cobertura por Busca Binária de Variação Significativa
2 Acessa arquivo de imagem da área a ser sensorizada
3 Apura comprimento da base em metros
4 Apura comprimento da altura em metros
5 Aplica malha externa sobre a imagem circundando a área a ser sensorizada
6 Enquanto na imagem tiver area vazia faça
7     Se cabe quadrante de (3,16 x 3,16 ha) então
8         desenha quadrante (3,16 x 3,16 ha)
9     Senao
10        dimensao quadrante = verifica dimensao possivel(area vazia)
11        Quadrante = desenha quadrante (dimensao quadrante)
12    Fim Se
13    atualiza area vazia(quadrante desenhado)
14    registra quadrante (id_quadrante, dimensao)
15 Fim Enquanto
16 GeraCarteziano(Registro de Quadrante n)
17 Para todos os quadrantes registrados faça
18     Aplica sobre a imagem os pontos de sensoriamento (registro de ponto de sensoriamento)
19     grava arquivo imagem com pontos de sensoriamento
20     Chama auxilio a aplicação dos sensores na área a ser sensorizada
21     Resultado Sensoriamento[]=Executa Sensoriamento(ponto de sensoriamento)
22     Ponto com Variacao = Verifica Diferenca(Resultado Sensoriamento)
23     Para cada Ponto com Variacao faça
24         dimensao quadrante = apura subquadrante(centro subquadrante)
25         Quadrante = desenha quadrante(dimensao quadrante)
26         Registra Quadrante(Quadrante)
27         GeraCarteziano(Registro de Quadrante n)
28     Fim Para
29 Fim Para
```

**Algoritmo 1. Algoritmo de Cálculo da distribuição dos sensores, baseado no método de Cobertura por Busca Binária de Variação Significativa (CBBVS). Fonte: Ferronato, Silva e Silva Neto (2018).**



**Figura 2. Representação do resultado do algoritmo através de ferramenta computacional. Fonte: Ferronato, Silva e Silva Neto (2018).**

### 3. RESULTADOS

Utilizando a ferramenta de distribuição dos sensores de proximidade dos atributos de solo baseado no modelo de distribuição CBBVS, chegou-se à primeira distribuição em quadrantes e pontos conforme apresentado na Figura 3. Manualmente foram inseridas as linhas (em amarelo), que representam as bordas exteriores da área a ser tratada.



Figura 3. Imagem primeira distribuição Unidade 1.

O ponto F foi desconsiderado por estar fora da área de interesse do sensoriamento por proximidade das concentrações dos atributos de solo.

Na Tabela 2 estão representadas as latitudes e longitudes de cada um dos pontos da distribuição inicial de maneira a informar o ponto exato de inserção dos sensores de proximidade dos atributos de solo.

Tabela 2. Distribuição georreferenciada dos pontos iniciais.

PONTO	LATITUDE	LONGITUDE
A	-24.053.417	-53.792.789
B	-24.055.213	-53.792.789
C	-24.053.417	-53.790.821
D	-24.055.213	-53.790.821
E	-24.053.417	-53.788.854
F	-24.055.213	-53.788.854

Todos os pontos centrais devem ser redistribuídos para que os quadrantes fiquem com a dimensão de 100m x 100m, conforme previsto na metodologia. Outro resultado

importante da redistribuição é a exclusão do processo de sensoriamento por estarem fora de ponto de interesse georreferenciado para os trabalhos de sensoriamento das concentrações dos atributos de solo a serem executados.

Na Figura 4 está representada a redistribuição do ponto A, sendo válidos os pontos 3 e 2 por se encontrarem dentro da área de interesse dos testes.



Figura 4. Imagem da primeira distribuição Unidade 1.

Na Tabela 3 estão representadas as latitudes e longitudes dos pontos de redistribuição que tiveram como centro o ponto A.

Tabela 3. Distribuição georreferenciada dos pontos iniciais.

PONTO	LATITUDE	LONGITUDE
2	-24.053.866	-53.792.297
3	-24.053.866	-53.793.281

Os resultados apresentados neste trabalho foram somente aqueles apurados com relação ao atributo Cálcio (Ca), primeiro para sintetizar os resultados e tornar viável sua apresentação no espaço disponível e segundo que estes resultados atendem a todos os requisitos para representar o trabalho completo com todos os outros atributos.

Em todos os resultados apresentados nas tabelas, as medições de Temperatura (T) e Umidade (U) estão representadas vinculadas às medições dispostas nos resultados para o atributo Cálcio (Ca).

Nos resultados apresentados mais à frente estão representadas as médias da Condutividade Elétrica (CE), que serão utilizadas no cálculo do desvio padrão destas

medições e posteriormente no cálculo do índice de correlação linear a ser apresentado. Este procedimento de cálculo de média e desvio padrão também é executado para a análise tradicional de solo, que posteriormente será utilizado para o cálculo do índice de correlação linear.

O primeiro passo para o cálculo do Coeficiente de Correlação Linear entre as medições de Condutividade Elétrica (CE) e as medições de Análise Tradicional (AT) é a apuração das médias destas medições.

As médias da condutividade elétrica e médias dos valores de análise de solo tradicional foram calculadas utilizando-se média aritmética simples, conforme representado a seguir:

$$\text{Media } n \text{ elementos}(CE \text{ ou } AT) = \sum n \text{ elementos} / n \quad (1)$$

onde CE = Condutividade Elétrica, AT = Análise Tradicional e n = Número de Elementos da amostra.

O segundo passo para o cálculo do Coeficiente de Correlação Linear entre as medições de Condutividade Elétrica (CE) e as medições de Análise Tradicional (AT) é a apuração do desvio padrão destas medições.

O desvio padrão das amostras de condutividade elétrica e de análise tradicional de solo é calculado conforme representado por:

$$DP \text{ amostra} = \sqrt{\frac{\sum_{n=1}^n |x_i - \mu|^2}{n}} \quad (2)$$

onde DP = Desvio Padrão da Amostra, n=Número de Elementos,  $\mu$ =Média dos Elementos, n = Número de Elementos da amostra e  $x_i$  é o i-ésimo elemento da amostra.

O terceiro passo para o cálculo do Coeficiente de Correlação Linear entre as medições de Condutividade Elétrica (CE) e as medições de Análise Tradicional (AT) é a apuração das diferenças destas medições e suas médias.

As diferenças entre as medições de condutividade elétrica e sua média e as diferenças entre as medições com análise tradicional são calculadas empregando:

$$Dif_i (CE \text{ ou } AT) = x_i - \text{Media } n \text{ Elementos} \quad (3)$$

onde  $Dif_i$  (CE ou AT) são as diferenças entre as medições de CE ou AT e sua média e  $x_i$  é o i-ésimo elemento da medição.

O quarto passo para o cálculo do Coeficiente de Correlação Linear entre as medições de Condutividade Elétrica (CE) e as medições de Análise Tradicional (AT) corresponde às diferenças apuradas.

A multiplicação das diferenças das medições de condutividade elétrica e análise tradicional e calculada conforme definido a seguir.

$$Mult\ Dif_i = Dif_i (CE) * Dif_i (AT) \quad (4)$$

onde i-ésimo elemento das amostras,  $Dif_i (CE)$  são as diferenças da Condutividade Elétrica e  $Dif_i (AT)$  são as diferenças da Análise Tradicional.

O quinto passo para o cálculo do Coeficiente de Correlação Linear entre as medições de Condutividade Elétrica (CE) e as medições de Análise Tradicional (AT) é a apuração do somatório da multiplicação das diferenças.

O somatório das multiplicações das diferenças é calculado por:

$$Som\ Mult\ Dif = \sum_{n=1}^n Mult\ Dif_i \quad (5)$$

O último passo é o cálculo do Coeficiente de Correlação Linear entre as medições de Condutividade Elétrica (CE) e as medições de Análise Tradicional (AT).

O coeficiente de correlação linear é utilizado por esta pesquisa para representar a relação entre a funcionalidade do sensor de condutividade elétrica e a concentração dos atributos de solo definidos para serem utilizados nesta pesquisa.

O coeficiente de correlação linear entre a amostra de condutividade elétrica medida e a amostra de análise tradicional de solos medida é calculado empregando:

$$CCL = Som\ Mult\ Dif / (n * DP_{ce} * DP_{at}) \quad (6)$$

onde CCL = Coeficiente de Correlação Linear, n = Número de Elementos,  $DP_{ce}$  = Desvio Padrão da Condutividade Elétrica e  $DP_{at}$  = Desvio Padrão da Análise Tradicional.

As faixas do coeficiente de correlação linear e suas explicações estão representados na Tabela 4.

**Tabela 4. Interpretação das faixas do Coeficiente de Correlação Linear.**

RANGE	INTERPRETAÇÃO	OBSERVAÇÃO
$0,0 \leq CCL < 0,2$	Correlação bem Fraca	Correlação Positiva
$0,2 \leq CCL < 0,4$	Correlação Fraca	Correlação Positiva
$0,4 \leq CCL < 0,7$	Correlação Moderada	Correlação Positiva
$0,7 \leq CCL < 0,9$	Correlação Forte	Correlação Positiva
$0,9 \leq CCL < 1,0$	Correlação Muito Forte	Correlação Positiva

Estas faixas criam a base necessária para a identificação e definição que o Coeficiente de Correlação Linear (CCL) mínimo necessário para gerar um grau de confiança aplicável em produção é de 0,9.

Na Figura 5 estão representadas as redistribuições dos pontos H, I, K, L, N e O sendo válidos todos os pontos por se encontrarem dentro da área de interesse dos testes.



Figura 5. Imagem da primeira distribuição na Unidade 1 de trabalho de campo.

Na Tabelas 5 estão representados as latitudes e longitudes dos pontos de redistribuição apresentados na Figura 5.

Tabela 5. Distribuição georreferenciada dos pontos de pesquisa.

PONTO CENTRAL	PONTO DE INTERESSE	LATITUDE	LONGITUDE
H	0	-24.056.005	-53.788.943
H	1	-24.055.556	-53.788.451
H	2	-24.056.454	-53.788.451
H	3	-24.056.454	-53.789.435
H	4	-24.055.556	-53.789.435
I	0	-24.057.802	-53.788.943
I	1	-24.057.353	-53.788.451
I	2	-24.058.251	-53.788.451
I	3	-24.058.251	-53.789.435
I	4	-24.057.353	-53.789.435
K	0	-24.056.005	-53.786.975
K	1	-24.055.556	-53.786.483
K	2	-24.056.454	-53.786.483
K	3	-24.056.454	-53.787.467
K	4	-24.055.556	-53.787.467

**Tabela 5. Distribuição georreferenciada dos pontos de pesquisa (continuação).**

PONTO CENTRAL	PONTO DE INTERESSE	LATITUDE	LONGITUDE
L	0	-24.057.802	-53.786.975
L	1	-24.057.353	-53.786.483
L	2	-24.058.251	-53.786.483
L	3	-24.058.251	-53.787.467
L	4	-24.057.353	-53.787.467
N	0	-24.056.005	-53.785.008
N	1	-24.055.556	-53.784.516
N	2	-24.056.454	-53.784.516
N	3	-24.056.454	-537.855
N	4	-24.055.556	-537.855
O	0	-24.057.802	-53.785.008
O	1	-24.057.353	-53.784.516
O	2	-24.058.251	-53.784.516
O	3	-24.058.251	-537.855
O	4	-24.057.353	-537.855

Os resultados do sensoriamento com protótipo de sensoriamento por proximidade dos atributos de solos na Unidade 1 do trabalho de campo estão aqui representados, tanto os valores de medição direta como Temperatura e Umidade quanto os valores de condutividade elétrica. Estão também representadas a distribuição espacial georreferenciada, conforme pode ser visto na Tabela 6.

Foram realizadas coleta de amostras nos pontos em todos os pontos apresentados nas tabelas associadas as imagens de distribuição dentro da área de interesse. Os resultados da medição dos atributos de solo através de análise tradicional realizada na unidade de teste podem ser vistos na Tabela 7 para cada um dos atributos tratados nesta pesquisa.

Os resultados de correlação entre a Condutividade Elétrica medida em cada ponto em relação à medição tradicional de cada ponto na Unidade 1 foi de 0,97 para uma amostra de 40 elementos de coleta, com um desvio padrão da CE medida de 1,18 e um desvio padrão da análise tradicional de 4,50.

**Tabela 6. Resultados dos sensoriamentos com o protótipo na Unidade 1 - período da manhã.**

Unidade 1			Solo	Argissolo Vermelho		Frequencia	500,00	Atributo	Calcio
Data	Hora	Quadrante	Ponto	Latitude	Longitude	Temperatura	Umidade	Condutividade Elétrica	Média CE
09/02/2018	9:00	E	0	-24053866	-53792297	27,94	89,37	21,01	22,04
09/02/2018	9:05	E	1	-24053866	-53793281	27,94	88,75	26,43	
09/02/2018	9:10	E	2	-24054764	-53792297	27,94	88,24	20,85	
09/02/2018	9:15	E	3	-24054764	-53793281	27,94	88,04	24,90	
09/02/2018	9:20	E	4	-24055213	-53790821	27,94	87,53	20,36	
09/02/2018	9:25	F	0	-24054764	-53790329	27,94	87,42	18,67	
09/02/2018	9:30	F	1	-24054764	-53791313	27,94	87,22	18,98	
09/02/2018	9:35	F	2	-24053417	-53790821	27,94	87,12	24,26	
09/02/2018	9:40	F	3	-24052968	-53790329	27,94	87,01	25,21	
09/02/2018	9:45	F	4	-24053866	-53790329	27,94	86,91	25,07	
09/02/2018	9:50	H	0	-24053866	-53791313	27,94	86,91	18,33	
09/02/2018	9:55	H	1	-24053417	-53788854	27,94	86,71	18,45	
09/02/2018	10:00	H	2	-24052968	-53788362	27,94	86,71	24,51	
09/02/2018	10:05	H	3	-24053866	-53788362	27,94	86,50	21,24	
09/02/2018	10:10	H	4	-24053866	-53789346	27,94	86,40	20,38	
09/02/2018	10:15	I	0	-24052968	-53789346	27,94	86,30	25,07	
09/02/2018	10:20	I	1	-24053866	-53792297	26,18	74,22	21,55	
09/02/2018	10:25	I	2	-24053866	-53793281	26,18	74,66	23,59	
09/02/2018	10:30	I	3	-24054764	-53792297	26,18	74,66	20,47	
09/02/2018	10:35	I	4	-24054764	-53793281	26,18	74,22	22,86	
09/02/2018	10:40	K	0	-24055213	-53790821	26,18	74,13	19,12	
09/02/2018	10:45	K	1	-24054764	-53790329	26,18	74,05	20,86	
09/02/2018	10:50	K	2	-24054764	-53791313	26,18	74,02	21,63	
09/02/2018	10:55	K	3	-24053417	-53790821	26,18	73,89	23,65	
09/02/2018	11:00	K	4	-24052968	-53790329	26,18	74,05	23,98	
09/02/2018	11:05	L	0	-24053866	-53790329	26,18	74,20	22,59	
09/02/2018	11:10	L	1	-24053866	-53791313	26,18	74,15	20,45	
09/02/2018	11:15	L	2	-24053417	-53788854	26,18	73,80	19,78	
09/02/2018	11:20	L	3	-24052968	-53788362	26,18	73,25	23,68	
09/02/2018	11:25	L	4	-24053866	-53788362	26,18	73,60	20,91	
09/02/2018	11:30	N	0	-24053866	-53789346	26,18	74,15	21,63	
09/02/2018	11:35	N	1	-24052968	-53789346	26,18	74,56	22,95	
09/02/2018	11:40	N	2	-24053866	-53789346	26,18	74,15	21,63	
09/02/2018	11:45	N	3	-24052968	-53789346	26,18	74,56	22,95	
09/02/2018	11:50	N	4	-24053866	-53789346	26,18	74,15	21,63	
09/02/2018	11:55	O	0	-24052968	-53789346	26,18	74,56	22,95	
09/02/2018	12:00	O	1	-24053866	-53789346	26,18	74,15	21,63	
09/02/2018	12:05	O	2	-24052968	-53789346	26,18	74,56	22,95	
09/02/2018	12:10	O	3	-24052968	-53789346	26,18	74,56	22,95	
09/02/2018	12:15	O	4	-24053866	-53789346	26,18	74,15	21,63	

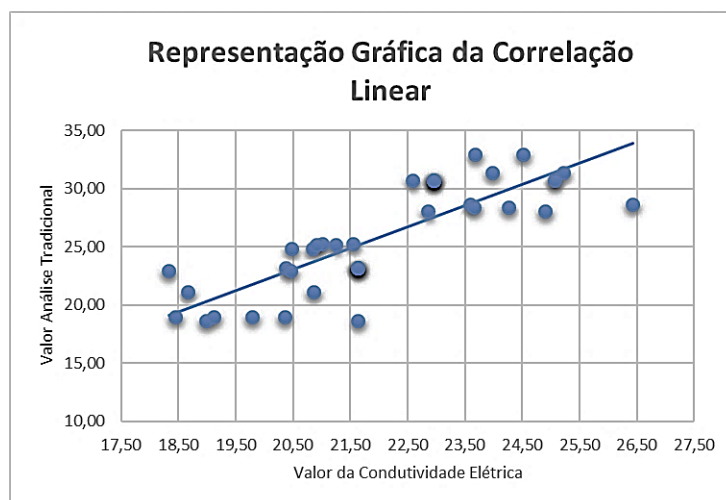


**Tabela 7. Medição dos Atributos físicos de solo tratados na pesquisa.**

PROFUNDIDADE : 0-20 cm			UNIDADE	cmol dm <sup>3</sup>
UNIDADE	DATA	QUADRANTE	PONTO	CALCIO
Trabalho de Campo 1	28/02/2018	E	0	25,27
Trabalho de Campo 1	28/02/2018	E	1	28,67
Trabalho de Campo 1	28/02/2018	E	2	24,87
Trabalho de Campo 1	28/02/2018	E	3	28,08
Trabalho de Campo 1	28/02/2018	E	4	18,95
Trabalho de Campo 1	28/02/2018	F	0	21,1
Trabalho de Campo 1	28/02/2018	F	1	18,67
Trabalho de Campo 1	28/02/2018	F	2	28,36
Trabalho de Campo 1	28/02/2018	F	3	31,37
Trabalho de Campo 1	28/02/2018	F	4	30,74
Trabalho de Campo 1	28/02/2018	H	0	22,91
Trabalho de Campo 1	28/02/2018	H	1	18,99
Trabalho de Campo 1	28/02/2018	H	2	32,92
Trabalho de Campo 1	28/02/2018	H	3	25,2
Trabalho de Campo 1	28/02/2018	H	4	23,17
Trabalho de Campo 1	28/02/2018	I	0	30,69
Trabalho de Campo 1	28/02/2018	I	1	25,27
Trabalho de Campo 1	28/02/2018	I	2	28,67
Trabalho de Campo 1	28/02/2018	I	3	24,87
Trabalho de Campo 1	28/02/2018	I	4	28,08
Trabalho de Campo 1	28/02/2018	K	0	18,95
Trabalho de Campo 1	28/02/2018	K	1	21,1
Trabalho de Campo 1	28/02/2018	K	2	18,67
Trabalho de Campo 1	28/02/2018	K	3	28,36
Trabalho de Campo 1	28/02/2018	K	4	31,37
Trabalho de Campo 1	28/02/2018	L	0	30,74
Trabalho de Campo 1	28/02/2018	L	1	22,91
Trabalho de Campo 1	28/02/2018	L	2	18,99
Trabalho de Campo 1	28/02/2018	L	3	32,92
Trabalho de Campo 1	28/02/2018	L	4	25,2
Trabalho de Campo 1	28/02/2018	N	0	23,17
Trabalho de Campo 1	28/02/2018	N	1	30,69
Trabalho de Campo 1	28/02/2018	N	2	23,17
Trabalho de Campo 1	28/02/2018	N	3	30,69
Trabalho de Campo 1	28/02/2018	N	4	23,17
Trabalho de Campo 1	28/02/2018	O	0	30,69
Trabalho de Campo 1	28/02/2018	O	1	23,17
Trabalho de Campo 1	28/02/2018	O	2	30,69
Trabalho de Campo 1	28/02/2018	O	3	30,69
Trabalho de Campo 1	28/02/2018	O	4	23,17

O gráfico resultante destes cálculos poder verificado na Figura 6, e aponta para uma correlação linear positiva e uma forte correlação entre Condutividade Elétrica e a concentração dos atributos de solo, com o coeficiente de correlação ficando entre 0,96 e 0,97.

Os índices de correlação linear sofreram intensas influências das adequações e calibrações realizadas no software dos sensores no que diz respeito ao fator de influência da umidade nos resultados da concentração dos atributos de solo.



**Figura 6. Gráfico de dispersão de correlação das variáveis nas unidades de campo.**

Com o aumento do fator de influência da umidade nas leituras das informações que deram origem à leitura da condutividade elétrica, aumentou-se os valores dos índices de correlação linear entre condutividade elétrica e medição tradicional dos atributos de solo.

Outro ponto bastante importante foi a necessidade de redistribuição dos pontos com variação significativa em relação ao padrão que atingiram em média trinta por cento (30%), dos pontos nas áreas destinadas ao trabalho de campo. As variações absolutas e em percentual ficaram bem próximas, mesmo a Unidade 1 tendo um solo com maior teor de argila.

De acordo com as medições na Unidade 1 foram obtidos os seguintes resultados:

- Medição 1: CE na camada alvo de solo de 0–30 cm variou entre 18,33 a 26,43 mS m<sup>-1</sup>, com valor médio de 22,4 mS m<sup>-1</sup> e um coeficiente de correlação de 0,96;
- Medição 2: CE na camada alvo de solo de 0–30 cm variou entre 18,93 a 25,83 mS m<sup>-1</sup>, com valor médio de 21,95 mS m<sup>-1</sup> e um coeficiente de correlação de 0,96;
- Medição 3: CE na camada alvo de solo de 0–30 cm variou entre 19,63 a 25,13 mS m<sup>-1</sup>, com valor médio de 22,02 mS m<sup>-1</sup> e um coeficiente de correlação de 0,97.

Na Unidade 1 os quadrantes que apresentaram maior variação dos valores de CE foram os seguintes: E, F e H. Na Unidade 2 os quadrantes com maior variação da CE foram G e J. As redistribuições nos quadrantes que sofreram as maiores variações foram efetuadas e os sensoriamentos complementares estão em fase de execução.

Nos trabalhos de campo os valores apurados chegaram à última faixa da tabela de identificação da acurácia do índice de correlação linear (vide Tabela 4), o que é considerado uma correlação positiva com grau de interpretação muito forte. Estes resultados garantem

o uso dos equipamentos e sistemas como forma de monitoramento e controle de concentração dos atributos de solo para o uso em agricultura de precisão.

#### 4. CONSIDERAÇÕES FINAIS

Na unidade de trabalho de campo a condutividade elétrica medida pelo sensor de proximidade em relação a análise tradicional apresentou um coeficiente de correlação linear variando entre 0,96 e 0,97 que se mostra adequada em relação à concentração dos atributos de solo da pesquisa, comparando-se com a análise tradicional o que permitiu uma distribuição adequada dos sensores através da ferramenta de distribuição. O desempenho nas unidades de trabalho de campo ficou dentro do esperado em relação ao grau de correlação da CE com os valores dos atributos de solo. Conforme pode ser verificado na tabela de faixas de coeficiente de correlação linear (vide Tabela 4).

Consolidando os trabalhos realizados em teste, piloto e campo pode-se afirmar que os estudos realizados, utilizando o sensor de proximidade dos atributos de solo, demonstraram que a CE tem um bom potencial para representar as variações nas concentrações dos atributos físicos e químicos de solo, indicando que esta medição associada ao método MMOADS-FECOMAP e à ferramenta de distribuição maximizada de sensores com CBBVS gerada nesta pesquisa, tem potencial para ser utilizado na caracterização espacial georreferenciada dos atributos de solos em Agricultura de Precisão.

Apresenta-se também como uma solução de baixo custo (R\$ 180,00 por hectare) em comparação à análise tradicional de solo, levando-se em consideração que para uso em agricultura de precisão são necessários na análise tradicional (R\$ 2.800,00 por hectare) 80 pontos de coleta por hectare.

Os resultados obtidos nas unidades de trabalho de campo com o ambiente proposto se mostraram adequados para uso em agricultura de precisão, após os ajustes e calibrações no software, possibilitando a obtenção de resposta consistente no que diz respeito à CE e as suas variações.

#### Agradecimentos

Os autores agradecem o apoio financeiro do IFFluminense, Embrapii, CNPq, Faperj e Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001.

## REFERÊNCIAS

- BRANDÃO Z.; ZONTA J.; MEDEIROS J.; SANA R.; FERREIRA J. (2017), **Condutividade elétrica aparente e sua correlação com o pH em solos no cerrado de Goiás**. Agricultura e Precisão.
- CANDÈS E. (2010), **The Power of Convex Relaxation: Near-Optimal Matrix Completion**. IEEE Transactions on Information Theory, USA.
- CELINSKI V.; ZIMBACK C.; CELINSKI T. (2009), **Resistência Elétrica e sua Correlação com a Granulometria do Solo Visando Aplicação na Agricultura de Precisão**. Botucatu, SP.
- DUTTA, R., MORSHED, A., ARYAL, J., D'ESTE, C., DAS, A. (2014), **Development of an intelligent environmental knowledge system for sustainable agricultural decision support**. Environmental Modelling & Software, p. 264–272.
- FERRONATO M. A. F.; SILVA S. V.; SILVA NETO, A. J. (2018), **Modelagem de Objetos para uma Ferramenta Computacional em Agricultura de Precisão para Distribuição Maximizada de Sensores de Aquisição dos Atributos de Solos por Proximidade**. Revista Cereus, v. 10, n. 2.
- FOUNTAS S., SORENSEN C.G., TSIROPOULOS Z. (2015), **Farm machinery management information system**, Computers and Electronics in Agriculture, p. 131–138.
- IBGE (2017), **Anais Estatísticas Agropecuária Brasil**. Disponível em: <www.ibge.gov.br>.
- KONE, C.T.; HAFID, A.; BOUSHABA, M. (2015), **Performance management of IEEE 802.15.4 wireless sensor network for precision agriculture**. IEEE Sensors Journal, p. 5734–5747.
- LUUS R.; HENNESSY D. (1999), **Optimization of Fed-Batch Reactors by the Luus-Jaakola Optimization Procedure**. American Chemical Society, USA.
- LUUS R., JAAKOLA T. (1973), **Optimization by Direct Search and Systematic Reduction of the Size of Search Region**. AIChE.
- MESAS-CARRASCOSA F.J., SANTANO D. V., MERONO J.E., ORDEN M. S., ´A-FERRER A. G. (2015), **Open source hardware to monitor environmental parameters in precision agriculture**. Disponível em: <http://sci-hub.cc/10.1016/j.biosystemseng.2015.07.005>. Acesso em: 25/9/2016
- RABELLO L.; BERNARD A.; INAMASU R. (2014), **Condutividade elétrica aparente do solo**. Agricultura e Precisão.
- SRINOVSKA, M.; GAVROVSKI, C.; DIMCEV, V.; KRKOLEVA, A. (2014), **Environmental parameters monitoring in precision agriculture using wireless sensor networks**. Journal of Cleaner Production, p. 1–11.