

CARACTERIZAÇÃO DE AMOSTRAS DE SOLO COM *SPECKLE* E BUSCA INTELIGENTE

Wellington Siqueira Porto

wellington.porto@fatec.sp.gov.br
Faculdade de Tecnologia de Itaquera

Mariane Stefany de Souza ¹

Faculdade de Tecnologia de Itaquera

Kauã Hiro dos Santos Mizumoto

Faculdade de Tecnologia de Itaquera

Sidney Leal da Silva

sidney.silva6@fatec.sp.gov.br
Faculdade de Tecnologia de Itaquera

1. INTRODUÇÃO

A caracterização do solo, especialmente relacionado à proporção de argila, areia e silte, é essencial para a definição das melhores práticas agrícolas [1-2]. A procura de novas metodologias e aperfeiçoamento de outras já existentes, para auxiliar na melhoria da produção agrícola, torna-se essencial para a melhoria da qualidade do plantio agrícola [3-4]. As metodologias ópticas vêm se apresentando como promissoras e modernas, associadas a sistemas computacionais capazes de efetuar os tratamentos de grandes quantidades de dados de forma rápida e eficiente, e poderão contribuir para o avanço dos estudos [5-6]. Este trabalho teve como propósito geral modelar e construir um banco de dados, algoritmos e programas computacionais para estimativas das curvas de intensidade relativa média de amostras de solo, não classificadas, dos materiais constituintes: argila, silte e areia. Os dados e os resultados foram obtidos em trabalho anterior [5] por técnica de interferometria *Speckle* estáticas das superfícies observadas e método computacional fundamentado nas teorias de THSP (*Time History Speckle Pattern* - História temporal do padrão *Speckle*) [7] e fundamentos da Teoria de Erros


[8], pelos pesquisadores do Grupo de Óptica e Aplicações da Fatec Itaquera, com amostras de solos fornecidas pelos pesquisadores do Laboratório de Solos e Tecido Vegetal da Fundação Nishimura de Tecnologia da Fatec Pompéia, fruto da parceria entre com o Grupo de Óptica da Fatec Itaquera.

2. METODOLOGIA

A metodologia óptica, denominada metodologia *Speckle*, para obtenção dos resultados para armazenamento no banco de dados utilizou como técnica um interferômetro *Speckle* por reflexão, para a coleta de dados (vídeos dos padrões de interferência *Speckle*) e os métodos THSP [7], Teoria de Erros, [8], e análise de intensidades por método gráfico, criado pelo Grupo de Óptica e Aplicações da Fatec Itaquera.

O banco de dados relacional foi construído a partir da modelagem de dados da Figura 01.

Figura 01 - Modelo de dados relacional.



Fonte: autoria própria

O processo de busca inteligente está diretamente associado à eficiente organização do banco de dados relacional. Isso proporcionou maior rapidez na combinação das informações contidas no banco e nos cálculos efetuados para estimar os valores das concentrações das amostras não identificadas. O algoritmo construído fundamentou-se em um dos métodos de busca com informação e exploração, denominado BUSCA-PELA-MELHOR-ESCOLHA, [9]. Um componente fundamental desse algoritmo é uma função heurística $h(n)$, que toma um nó como entrada, mas depende apenas do estado desse nó:

$$h(n) = \text{custo estimado do caminho mais econômico do nó } n \text{ até um nó objetivo} \quad (1)$$

Por exemplo, no Brasil, poderíamos estimar o custo do caminho mais econômico deste São Paulo até o Rio de Janeiro pela distância em linha reta entre as duas cidades. As funções heurísticas são a forma mais comum de aplicar conhecimento adicional do problema ao algoritmo de busca. Uma boa estratégia, nessa direção, é utilizar a busca gulosa pela melhor escolha, que tenta expandir o nó mais próximo à meta, na suposição de que isso provavelmente levará a uma solução rápida. Desse modo, ela avalia nós usando apenas a função heurística: $f(n) = h(n)$. No problema de localização de rotas no Brasil, usando a função heurística de distância em linha reta (h_{DLR}), se o objetivo é Rio de Janeiro, a partir de São Paulo, precisaremos conhecer as distâncias entre algumas cidades, em linha reta, até o Rio de Janeiro, mostradas na Tabela 01.


Tabela 01 — Médias das estimativas de concentrações.

São Paulo	388 km
Taubaté	269 km
Aparecida do Norte	252 km
Rio de Janeiro	0 km
São José dos Campos	309 km
Volta Redonda	107 km
Resende	152 km

Fonte: tabela modificada da referência [9]

Os valores de h_{DLR} não podem ser calculados a partir da descrição do problema e é necessária uma certa experiência para saber que h_{DLR} está relacionada com distâncias rodoviárias reais e que, portanto, é uma heurística útil. A Figura 02 mostra o progresso de uma busca gulosa pela melhor escolha usando h_{DLR} para encontrar um caminho de São Paulo até o Rio de Janeiro. O primeiro nó a ser expandido a partir de São Paulo será Taubaté, porque está mais próximo do Rio de Janeiro do que São José dos Campos. O próximo nó a ser expandido será Resende porque está mais próximo do Rio de Janeiro do que Aparecida do Norte e assim por diante.

Figura 02 - Fases de uma busca gulosa pela melhor escolha para o Rio de Janeiro, usando-se a heurística de distância em linha reta h_{DLR} .



Fonte: figura modificada da referência [9]

A busca gulosa pela melhor escolha é semelhante à busca em profundidade, pelo fato de preferir seguir um único caminho até o objetivo, mas voltará ao encontrar um beco sem saída. Ela tem os mesmos defeitos da busca em profundidade (não é ótima e é incompleta, pois pode entrar em um caminho infinito e nunca retornar para experimentar

outras possibilidades). A complexidade de tempo e espaço do pior caso é $O(b_m)$, onde m é a profundidade máxima do espaço de busca. Porém, com uma boa função heurística, a complexidade pode ter uma redução substancial. A proporção da redução depende do problema específico e da qualidade da heurística [9].

Utilizando-se os valores de intensidades, obtidas pela metodologia *Speckle*, de uma amostra “não identificada” (com valores de concentrações, em g/kg, dos materiais componentes areia, argila e silte), estimou-se os melhores percentuais de concentrações pelos programas computacionais inteligentes, por buscas e comparações aos valores dos percentuais de concentrações de amostras catalogadas e identificadas, devidamente armazenados no banco de dados relacional. Com esses resultados, foram estimadas as concentrações, em g/kg, de areia, argila e silte, nas amostras, que foram comparados aos valores determinados pelos processos tradicionais, atualmente realizados na Agricultura.

3. RESULTADOS E DISCUSSÕES

O programa inteligente utilizou o banco de dados relacional e as informações de intensidade relativa de 3 amostras “não identificadas” para determinações das estimativas de suas concentrações, em g/kg. A Tabela 02 apresenta os resultados estimados obtidos pela metodologia apresentada.

Tabela 02 – Médias das estimativas de concentrações.

Amostra teste	Concentração (g/kg) (areia)	Concentração (g/kg) (argila)	Concentração (g/kg) (silte)
111214/4 (argilosa) - tradicional	278,0 ± 13,9	579,0 ± 29,0	193,0 ± 9,7
111214/4 (argilosa) - estimativa	194,6 ± 7,2	376,4 ± 16,5	112,9 ± 16,5
111215-3 (arenosa) - tradicional	70,0 ± 3,5	858,0 ± 42,9	72,0 ± 3,6
111215-3 (arenosa) - estimativa	98,9 ± 5,3	631,9 ± 32,2	85,3 ± 4,7
116201-8 (siltosa) - tradicional	147,0 ± 7,4	325,0 ± 16,3	528,0 ± 26,4
116201-8 (siltosa) - estimativa	183,1 ± 8,5	372,6 ± 18,4	415,9 ± 19,2

Fonte: autoria própria.

Para cada amostra teste, na Tabela 02, são apresentados os valores obtidos pela metodologia tradicional da agricultura e por meio da estimativa realizada pelo presente trabalho.

4. CONCLUSÕES

Os valores das concentrações estimadas, nas três amostras teste estudadas, mostraram-se coerentes com os maiores teores para cada amostra. Por exemplo, na amostra 111214/4 (argilosa), embora as concentrações sejam diferentes, os valores estimados de concentrações são preservados em termos de proporções, maior concentração para a argila, média concentração para a areia e menor concentração para o silte.

Isso mostra que os algoritmos estão no caminho certo, mas ainda precisam de: (i) melhorias no processo de busca e cálculos; (ii) mais informações de intensidades relativas, a partir da metodologia *Speckle*, para alimentar o banco de dados. Quanto mais dados, maior a tendência de as estimativas levarem aos valores mais reais. Estas duas perspectivas estão previstas para as próximas fases dos trabalhos.

As próximas fases do trabalho utilizarão outros algoritmos de busca ao banco de dados relacional, que também será melhorado desde a modelagem até a implementação. Enquanto isso, novas medições serão realizadas pela metodologia *Speckle*, utilizando novas amostras que serão fornecidas pelo Laboratório de Solos e Tecido Vegetal da Fundação Nishimura de Tecnologia da Fatec Pompéia.

REFERÊNCIAS

- [1] CENTENO, L. N.; Guevara, M. D. F.; Cecconello, S. T.; Souza, R. O. D.; Timm, L. C. Textura do solo: conceitos e aplicações em solos arenosos. Revista Brasileira de Engenharia e Sustentabilidade (Pelotas - RS), v. 4, n. 1, p. 31-37, 2017. ISSN: 2448-1661
- [2] KLEIN, V. A.; Baseggio, M.; Madalosso, T.; Marcolin, C. D. Textura do solo e a estimativa do teor de água no ponto de murcha permanente com psicrômetro. Ciência Rural – Santa Maria, v. 40, n. 7, p. 1550-1556, 2010. ISSN: 0103-8478
- [3] FAULIN, G. D. C et al. Aplicação da Metodologia *Speckle* na investigação da

- classe textural do solo. Congresso Brasileiro de Agricultura de Precisão, ConBAP. Campinas, 2022
- [4] PAULA, M. E. C. C.; Duarte, M. N.; Claessen, M. E. C.; Barreto, W. de O. Manual de métodos de análise de solo. Segunda edição. Rio de Janeiro, Centro Nacional de Pesquisas do Solo da Embrapa, 212 p., 1997. ISBN: 85-85864-03-6
- [5] DA SILVA, Sidney et al. Differentiation of Clay Content in Soil Samples Containing Clay, Silt, and Sand Using the Speckle Methodology. *Brazilian Journal of Physics*, v.55, n.5, p.211, 2025.
- [6] SANTOS, L. D. V.; Enes, A. M.; Holanda, F. S. R.; Oliveira, C. V. S.; Pedroti, A. Avaliação do comportamento do biospeckle em diferentes níveis de umidade do solo. *Brazilian Journal of Development*, v. 6, n. 7, p. 52891-52908, 2020. DOI: 10.34117/bjdv6n7-892
- [7] BRAGA, R. A. et al. Time history speckle pattern under statistical view. *Optics Communications*, v. 281, n. 9, p. 2443-2448, 2008.
- [8] VUOLO, J. H. Fundamentos da Teoria de Erros. 2ª edição. São Paulo: Editora Edgard Blucher Ltda, 264 p., 1996.
- [9] RUSSEL, S.; NORVIG, P. Inteligência Artificial. Tradução da segunda edição por Vanderberg D. de Souza. Rio de Janeiro: Elsevier, 1021 p., 2004.

AGRADECIMENTOS

Agradecimentos ao Laboratório de Óptica e Aplicações da FATEC Itaquera e ao Laboratório de Solos e Tecido Vegetal da Fundação Nishimura de Tecnologia da Fatec Pompéia.

¹Aluna de Iniciação Tecnológica do CNPq-PIBITI