

## USO DE IMAGENS LANDSAT 8 NA GERAÇÃO DE VALORES DE CURVA-NÚMERO (CN) PARA GRANDES ÁREAS

ELISA DE MELLO KICH<sup>1</sup>

TATIANA S. DA SILVA<sup>2</sup>

FERNANDO MAINARDI FAN<sup>3</sup>

ANDREA L. IESCHECK<sup>4</sup>

<sup>1,2,4</sup>Laboratório de Modelagem de Bacias, Instituto de Geociências - UFRGS

<sup>3</sup>Instituto de Pesquisas Hidráulicas - UFRGS

elisakich@gmail.com, tatiana.silva@ufrgs.br, fernando.fan@ufrgs.br, andrea.iescheck@ufrgs.br

**RESUMO** - O monitoramento do uso e cobertura do solo se faz importante para construção de modelos hidrológicos, onde o cruzamento entre dados de cobertura e uso do solo e o tipo hidrológico de solo pode ser usado para estimar a sua capacidade de infiltração, expressa através de valores de curva-número (CN). O presente trabalho teve como objetivo avaliar o potencial de uso de imagens Landsat8 através da construção de algoritmos baseados em SIG para a geração de valores de CN. Para tal, foram realizados testes de correlação em SIG entre índices de vegetação e mapas de CN gerados a partir de mapas de uso e cobertura do solo combinados com mapas de tipos hidrológicos de solo. O CN estimado pelo NDVI proporcionou a integração entre o produto do tratamento das imagens e os valores pré-estabelecidos de CN, mostrando-se uma ferramenta auxiliar útil nos estudos de infiltração em amplas regiões. Portanto esse método pode ser considerado uma forma semi-automática de obter valores CN.

**ABSTRACT** - The land cover monitoring it's important for building hydrological models, where the crossing between the land cover and the soils hydrological type data can be used to estimates its infiltration capacity, expressed through values of curve number (CN). The goal of this work is to evaluate the use of Landsat images potential, by building algorithms based in GIS, in generating CN values. For this, there were applied correlation tests in GIS between vegetation indexes, and CN maps generated from land cover maps combined with soil hydrological type maps. The estimated CN by the NDVI image provided the integration between the images treatment product and the CN pre-established values for different combinations between land cover and hydrologic type of soils, showing itself as a useful and helpful tool for the large areas infiltrations studies. Therefore this method can be considered a semi-automatic scheme to obtain CN values.

### 1 INTRODUÇÃO

Atualmente as questões relativas ao meio ambiente são tema presente em várias esferas de conhecimento. Sabe-se da importância de preservar recursos e ecossistemas, entretanto, tornar ações práticas nem sempre é simples. Além disso, pode necessitar recursos financeiros não disponíveis. Portanto, criar novas tecnologias para facilitar o monitoramento ambiental é importante para tomadas de decisão.

Particularmente nos estudos de grandes enchentes e inundações ainda existem muitos fatores a serem estudados para melhor analisar o porquê das ocorrências e, conseqüentemente, como evitá-las. O estudo da geração de escoamento superficial é de grande relevância para assuntos relacionados ao meio ambiente, pois através do cálculo da lâmina escoada é possível prever a ocorrência de cheias e inundações, sendo assim uma ferramenta importante que pode auxiliar para evitar esse tipo de desastre em função da ocupação urbana em áreas de risco como leitos de inundações de rios.

Para avaliar a quantidade de água precipitada que pode vir a se transformar em cheia é preciso analisar o percurso da água a partir de quando ela toca o solo. Com o uso de algumas equações pode-se chegar a valores muito próximos da real vazão gerada pela chuva.

A geração do escoamento é um dos temas mais complexos da hidrologia uma vez que a variabilidade das características da bacia é muito grande, e porque a água pode tomar vários caminhos desde o momento em que atinge a superfície, na forma de chuva, até o momento em que chega ao curso d'água (COLLISCHON e DORNELLES, 2013).

Para estimar os volumes de água escoados nos diferentes locais que compõem uma região de interesse, calcula-se a lâmina escoada durante a chuva. Para isso, pode-se usar o parâmetro adimensional CN (Curva Número). Esse coeficiente leva em consideração a capacidade de infiltração do solo e o tipo de uso do solo, ou seja, se a região estudada é uma floresta, uma cidade, uma plantação, etc.

Para definir o parâmetro CN de uma determinada área são necessários dados sobre o grupo hidrológico de solo e a cobertura e uso do solo. O primeiro pode ser considerado constante se for levada em conta a escala temporal das atividades humanas. O segundo, entretanto, pode sofrer grande variação em curtos períodos de tempo, dependendo da região. Mapear esse processo demanda tempo e recursos humanos especializados, o que pode elevar os custos de forma a inviabilizar os estudos. Sendo assim, desenvolver maneiras automáticas para definição do CN pode representar uma economia significativa de tempo e de recursos, tornando o projeto mais ágil, bem como compatível com a velocidade das mudanças na cobertura e uso do solo e com a demanda por modelos hidrológicos aplicados ao gerenciamento de desastres.

Assim, o objetivo deste trabalho é avaliar o potencial de uso de imagens *Landsat 8*, através da construção de algoritmos baseados em SIG na geração de valores de CN. Para tal, foram aplicados índices de vegetação, álgebra com mapas e testes estatísticos em SIG.

## 2 MATERIAL E MÉTODOS

### 2.1 Área de estudo

A área de estudo escolhida faz parte do litoral norte do Rio Grande do Sul, corresponde à área coberta pela cena *Landsat 220\_081* e está indicada pela Figura 1. Na última década, a região do Litoral Norte apresentou taxa média de crescimento demográfico anual de 2,81%. Este indicador é significativo, se comparado às taxas anuais do Estado (1,23%) e do Brasil (1,63%) (FARINA 2011).

A evolução dessa região se deu através de quatro transgressões marinhas, responsáveis pela formação das quatro barreiras marinhas e remodelação do relevo anteriormente tomado pelo basalto da Serra Geral e pelo Arenito Botucatu, formando pacotes sedimentares das planícies e parte das encostas de morros interiores da planície costeira interna (FARINA 2009).

A região da Planície Costeira do Rio Grande do Sul apresenta, de acordo com Nimer (1977), um clima mesotérmico brando, superúmido, sem estação seca. A temperatura média anual oscila entre 16 e 20°C. A média do mês mais quente fica entre 22 e 26°C e a média do mês mais frio entre 10 e 15°C. A precipitação pluviométrica anual varia entre 1.000 e 1.500 mm (VILLWOCK e TOMAZELI 2000).

A região escolhida possui um histórico recente de eventos de enchente, alagamento e inundação, sendo que a defesa civil chegou a ser acionada dez vezes no período de abril de 2005 a janeiro de 2010 na área (MÜLLER 2014).



Figura 1 – Localização da área de estudo

## 2.2 Estrutura de dados

O estudo realizado contou com a utilização dos seguintes tipos de dados espaciais:

(1) Imagens de sensoriamento remoto – Para geração de mapas de uso do solo foi utilizada a imagem *Landsat 8* para a cena 220\_081 adquirida em 29 de dezembro de 2013. Esta foi fornecida gratuitamente pelo *Landsat Look Viwer* (<http://landsatlook.usgs.gov>). As imagens *Landsat* são de fácil obtenção e tem a qualidade necessária para esse trabalho em termos radiométricos e geométricos.

(2) Tabelas de valores CN – A tabela com os valores de curva número (CN) utilizada foi obtida de Tucci *et al.*(1993).

(3) Imagens Classificadas de cobertura e uso do solo – Para obtenção das imagens classificadas de cobertura e uso do solo utilizou-se a metodologia de Anderson (1976) adaptada.

(4) *Google Earth* – Utilizado para a verdade de campo e a verificação da precisão obtida pelas imagens classificadas de uso de solo.

(5) Mapa de solos do RS – Obtido do IBGE, o mapa de escala 1:1.000.000 traz as informações necessárias para a montagem do mapa de grupos hidrológicos.

## 2.3 Procedimentos analíticos

### 2.3.1 Índices de Vegetação NDVI

O NDVI (*Normalized Difference Vegetation Index*) é um índice que possibilita analisar a densidade vegetal numa região. Sua geração se dá pela diferença entre a reflectância do infravermelho próximo e a reflectância do vermelho, dividida, respectivamente, pela soma das duas refletâncias (TOWNSHEND apud SOUZA, 2010), como mostra a equação (1).

$$NDVI = \frac{(IVP - V)}{(IVP + V)} \quad (1)$$

em que, *IVP* é a reflectância do infra-vermelho próximo e *V* é a reflectância do vermelho.

O resultado dessa equação é um índice com valores que variam de -1 a 1. Sendo que, os valores mais próximos de 1 representam vegetação, os valores próximos de 0 representam solo exposto e os valores próximos de -1 representam água. É importante lembrar aqui que no satélite *Landsat 8* o vermelho e o infravermelho correspondem às bandas 5 e 6 respectivamente, diferente do *Landsat 7*, onde estas faixas do espectro correspondem às bandas 4 e 5.

### 2.3.2 Clustering

O classificador de imagens chamado *cluster* é um classificador não supervisionado, isto é, ele não depende que o operador informe as características espectrais de cada classe. O *software* procede a separação de classes a partir da análise da imagem em diferentes bandas e gera grupos espectrais. Neste trabalho, as imagens cluster foram utilizadas como auxiliares na definição de amostras para a classificação supervisionada, caracterizando o procedimento de classificação do trabalho como um todo como uma classificação híbrida.

### 2.3.3 Classificador KNN

O mapa de cobertura e uso do solo da região estudada foi gerado a partir da ferramenta KNN do IDRISI Selva. Essa é uma ferramenta de classificação supervisionada que usa o vizinho mais próximo de um subconjunto de todas as amostras para determinar a classe de um *pixel* ou o seu grau de adesão a uma classe.

Esse classificador gera duas imagens de cobertura e uso do solo: uma do tipo “*hard classification*”, onde todos os *pixels* são atribuídos a uma única classe, e outra do tipo “*soft classification*”, onde os *pixels* apresentam um valor da probabilidade de pertencer a uma ou outra classe.

As imagens “*soft*” auxiliam a corrigir a imagem “*hard*” gerada, pois esta última pode vir com erros significativos, atribuindo determinadas classes a locais onde existem outros usos do solo que não o calculado pelo classificador. Para realizar essa correção, a imagem “*soft*” da classe que se quer corrigir é analisada junto ao *Google Earth*. A imagem “*soft*” é dotada de *pixels* com diferentes valores de probabilidade de pertencerem a determinada classe e, então, essa imagem é analisada junto ao *Google Earth* para saber a partir de qual valor probabilístico os *pixels* eram de fato referentes a regiões daquela classe. A partir daí a imagem é reclassificada para valores de um para os valores que se tinha certeza que eram de áreas daquela classe e de zero para valores que se tinha certeza que não eram de áreas daquela classe e o produto dessa reclassificação é “encaixado” na imagem “*hard*” a partir de uma operação do tipo *Overlay*, gerando o resultado final do mapa de cobertura e uso do solo.

A imagem de valores CN, portanto, foi gerada pela tabulação cruzada entre o mapa de cobertura e uso do solo e o mapa de grupos hidrológicos de solo.

### 2.3.4 Definição da acuracidade

Para avaliar o nível de acertos obtidos no método de classificação de uso do solo, foi feita uma avaliação de acuracidade por um método desenvolvido pelo *National Park Service Vegetation Inventory*. Esse método diz que, para as classes que tiverem mais do que 50 ha de área, deverão ser amostrados 30 pontos. Com base nas observações de Stehman & Czaplewski (1998) foi escolhida uma distribuição randômica de amostras do tipo “ponto”. A utilização de pontos permite a avaliação de áreas circundantes para a sua rotulação, mas ao mesmo tempo evita problemas relacionados às distribuições de polígonos ou pixels.

### 2.3.5 Teste de correlação

Para avaliar a correlação entre as duas imagens obtidas (mapa de valores CN e imagem NDVI), a ferramenta *Regress* do IDRISI Selva foi usada. Essa aplicação é capaz de realizar uma regressão linear entre os dados das duas imagens e indicar o nível de correspondência entre as elas através do valor de “r”.

## 3 RESULTADOS E DISCUSSÃO

### 3.1 NDVI

A Figura 2 mostra o resultado da geração da imagem NDVI, onde os pixels de valor próximos a -1 representam água, valores próximos a zero solo exposto e valores próximos a 1 vegetação.

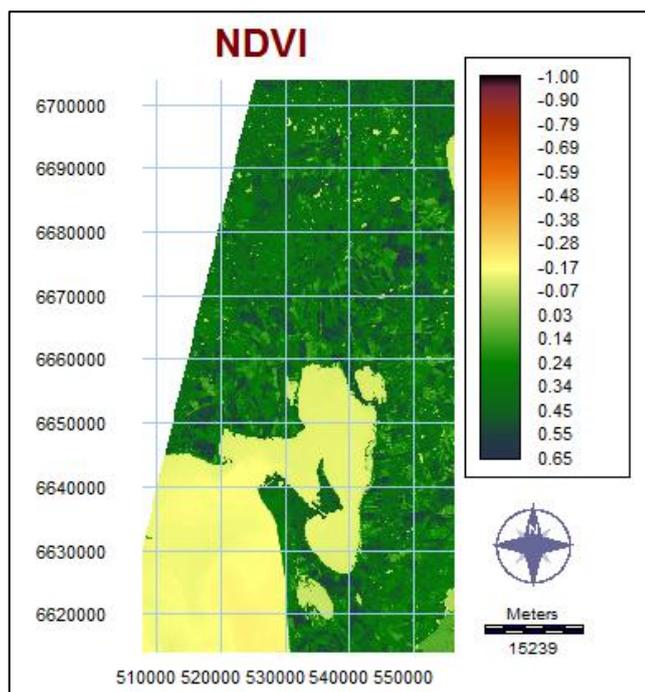


Figura 2 – Imagem NDVI

### 3.2 Mapa de cobertura e uso do solo

O uso isolado dos resultados do procedimento de *Clustering* não se mostrou adequado, em uma avaliação puramente visual, dada a evidente confusão espectral para alguns tipos de cobertura e uso do solo como, por exemplo, entre as classes de mata nativa, silvicultura e plantações verdes. Entretanto, a imagem gerada por *Clustering* foi auxiliar no processo de criação de amostras para definição das classes de uso do solo na classificação supervisionada.

Uma vez que o resultado do procedimento final de classificação fornece um maior nível de diferenciação de classes de cobertura e uso do solo do que o necessário para o presente trabalho, foi feita uma reclassificação a fim de

simplificar este mapa de forma que melhor refletisse as variações de CN na área de estudo (muitas das classes pré-reclassificação apresentariam o mesmo valor de CN). Além disso, a classe de uso do solo “urbano” apresentou erros diversos, como muita mescla com as classes de vegetação baixa. Por este motivo, nesta reclassificação, a classe “urbano” foi fundida com as classes de vegetação baixa, para ser trabalhada posteriormente. Foi, então, feita uma avaliação da imagem classificada tipo “soft” para identificar a partir de qual valor de probabilidade dos *pixels* pertencerem à classe “urbano” havia um nível maior de acerto na detecção de áreas realmente urbanas. Constatou-se que a partir de 0.65 de probabilidade de pertencer à classe urbana os pixels tendem realmente a pertencer a essa classe. Com isso, a imagem do tipo “soft” foi reclassificada com valores de zero para probabilidades menores que 0.65 e valores de 1 para probabilidades maiores que 0.65. O produto dessa reclassificação foi, então, sobreposto à imagem resultante do procedimento de classificação tipo “hard”. É importante lembrar que os valores de CN para áreas urbanas tendem a ser muito próximos uma vez que áreas asfaltadas, concretadas e outros tipos de áreas impermeabilizadas são o cenário mais abundante nas cidades em tem um tipo de infiltração muito parecida. O resultado final corresponde ao mapa de cobertura e uso do solo (Figura 3).

Com relação à avaliação da acuracidade do mapa de cobertura e uso do solo, foram obtidos 289 acertos dos 300 pontos analisados, o que representa 96,3 % de acuracidade total, sendo que a acuracidade mínima esperada para este tipo de procedimento é de 85%.

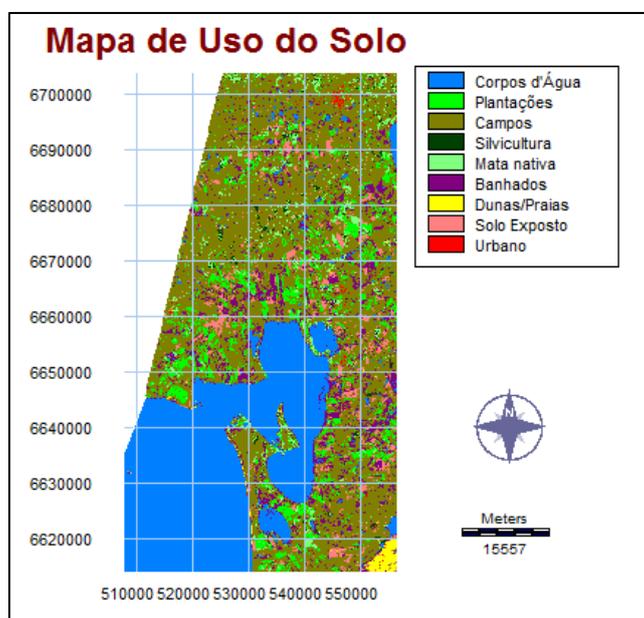


Figura 3 – Imagem de cobertura e uso do solo

### 3.3 Mapa de tipos Hidrológicos de Solos

Para obter o mapa de tipos hidrológicos de solo, foi necessário fazer a reclassificação de um mapa de Solos do RS enquadrando cada tipo de solo nas categorias A, B, C ou D, onde A é o tipo com a maior capacidade de infiltração e D com a menor. Para isso foi feita uma pesquisa na EMBRAPA sobre os tipos de solo existentes no mapa de solos para que fosse possível enquadrá-los de acordo com o seu tipo de permeabilidade. A Figura 4 mostra o mapa final de tipos hidrológicos obtido apenas para a região de estudo.

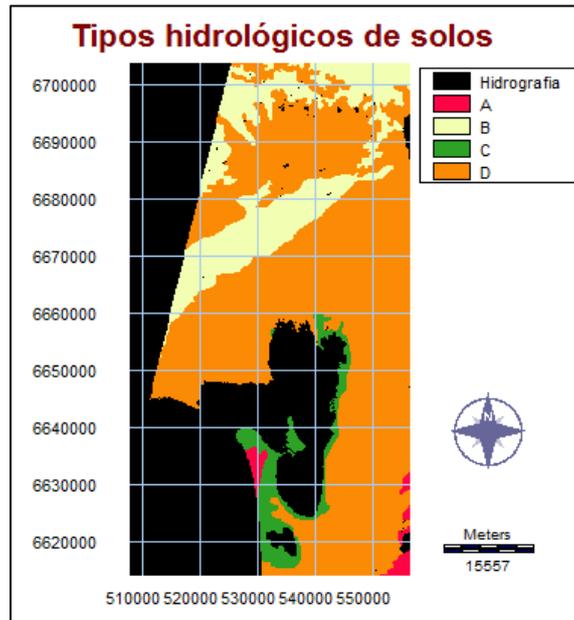


Figura 4 – Mapa de tipos hidrológicos de solos

### 3.4 Mapa de CN

Para finalmente chegar ao mapa CN foi feito um cruzamento de dados entre o mapa de uso do solo e o mapa de tipos hidrológicos de solo. A Figura 5 mostra o resultado desse cruzamento. Essa imagem trouxe valores de combinações de tipos hidrológicos de solo e usos do solo, sendo assim possível fazer uma reclassificação da imagem, atribuindo valores de CN para cada combinação correspondente.

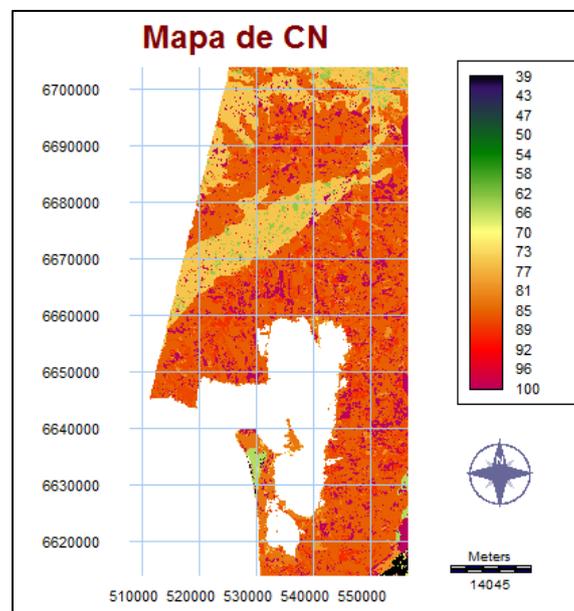


Figura 5 – Mapa de CN

### 3.5 Análise de Correlação

Com as imagens chave finalizadas, foi então realizado o teste de regressão linear simples. O teste foi realizado com o Mapa de CN e com a imagem NDVI.

O resultado do teste de correlação a foi de 73%. A equação 2 expressa a relação entre as duas variáveis. O desvio padrão para x foi de 0.23 e para y de 9.85 para uma amostra de aproximadamente 5 milhões de pixels. Esse resultado é bastante satisfatório se for considerado o fato de que a obtenção de mapas CN é demorada e depende de mapas de solos que são raros.

$$Y = 96,146667 - 30,545530X \quad (2)$$

## 4 CONCLUSÃO

Através deste trabalho ficou claro o longo caminho necessário para a obtenção de Mapas CN. Começando pela classificação de imagens, seguido por trabalhos de reclassificação e testes de acuracidade, depois fazendo um trabalho com mapas de uso do solo pra transformá-los em mapas de tipos hidrológicos de solo e então cruzar esse último com o mapa resultante da imagem classificada para finalmente reclassificá-la de acordo com as combinações obtidas atribuindo-lhes os valores de CN correspondentes.

Percebe-se assim, que esse longo caminho pode ser substituído por uma imagem NDVI é facilmente obtida através de uma única operação em SIG, pois o resultado obtido na regressão linear simples foi satisfatório.

Sendo assim, recomenda-se uso de imagens NDVI como substituto de mapas CN para grandes áreas uma vez que esse recurso é muito mais simplificado se comparado com a obtenção de mapas CN.

Os resultados obtidos podem ser usados para a modelagem hidrológica da ocorrência de cheias nas áreas de estudo. Da mesma forma, as técnicas aqui estudadas podem ser aplicadas para outras regiões com o mesmo objetivo. Espera-se que a técnica apresentada permita uma abordagem mais eficiente em termos de tempo e recursos para a delimitação de valores de CN a serem usados em estudos hidrológicos de grandes áreas.

## AGRADECIMENTOS

Agradeço à Pró-Reitoria de Gestão de Pessoas da UFRGS. Ao *Landsat Look Viewer* pelo fornecimento das imagens e à Equipe do Laboratório de Modelagem de Bacias pela edição e disponibilidade de dados vetoriais.

## REFERÊNCIAS

COLLISCHONN, W.; DORNELLES, F. **Hidrologia para Engenharia e Ciências Ambientais**. Porto Alegre: Associação Brasileira de Recursos Hídricos (ABRH), 2013. 336p.

EMBRAPA. Empresa Brasileira de Pesquisas Agronômicas. Disponível em: <<https://www.embrapa.br>>. Acesso em: 16 jun. 2014.

FARINA, F. C. **Sistemas de informação geográfica (SIG) Estratégico do potencial energético renovável da Planície Costeira Norte do RS.** Tese (Doutorado em Geociências) - Instituto de Geociências, Curso de Pós-Graduação. Porto Alegre: Universidade Federal do Rio Grande do Sul, 2009. 150 f.

IBGE. **Mapa de Solos Simplificado do Rio Grande do Sul**. Instituto Brasileiro de Geografia e Estatística (IBGE), Diretoria de Geociências, EMBRAPA Solos, Centro Nacional de Pesquisas de Solos, 2002.

TUCCI, M. C. E. **Hidrologia: Ciência e Aplicação**. Porto Alegre: UFRGS/ABRH, 4ª Edição, 2009.

VILLWOCK, J. A.; TOMAZELLI, L. J. **Planície Costeira do Rio Grande do Sul: gênese e paisagem atual**. 2000. Cap. 2. P 21.