

UNIVERSIDADE FEDERAL DE MINAS GERAIS
INSTITUTO DE GEOCIÊNCIAS
DEPARTAMENTO DE GEOGRAFIA

Grazielle Anjos Carvalho

Contribuições metodológicas ao Planejamento Urbano:
*Comparação de métodos de análise multivariada e Modelos de
Simulação da paisagem urbana – aplicações na Regional Pampulha -
Belo Horizonte, Minas Gerais - Brasil.*

Belo Horizonte, MG
2015

Grazielle Anjos Carvalho

Contribuições metodológicas ao Planejamento Urbano:

Comparação de métodos de análise multivariada e Modelos de Simulação da paisagem urbana – aplicações na Regional Pampulha - Belo Horizonte, Minas Gerais - Brasil.

Tese apresentada ao Programa de Pós-Graduação do Departamento de Geografia da Universidade Federal de Minas Gerais, como requisito à obtenção do título de Doutor(a) em Geografia.

Área de concentração: Análise Ambiental

Orientador: Prof. Dr. Ana Clara Moura Mourão - UFMG.

Belo Horizonte, MG
Geografia e Análise Ambiental
Instituto de Geociências , UFMG
2015

C331c
2015

Carvalho, Grazielle Anjos.

Contribuições metodológicas ao planejamento urbano [manuscrito] : comparação de métodos de análise multivariada e modelos de simulação da paisagem urbana – aplicações na Regional Pampulha - Belo Horizonte, Minas Gerais - Brasil / Grazielle Anjos Carvalho – 2015.

xix, 155 f., enc.: il. (principalmente color.)

Orientadora: Ana Clara Moura Mourão.

Tese (doutorado) – Universidade Federal de Minas Gerais, Departamento de Geografia, 2015.

Área de concentração: Análise Ambiental.

Bibliografia: f. 146-155.

1. Planejamento urbano – Belo Horizonte (MG) – Teses. 2. Paisagens – Belo Horizonte (MG) – Teses. 3. Análise multivariada – Teses. I. Mourão, Ana Clara Moura. II. Universidade Federal de Minas Gerais, Departamento de Geografia. III. Título.

CDU: 711.4(815.1)



FOLHA DE APROVAÇÃO

**Contribuições metodológicas ao Planejamento Urbano:
Comparação de métodos de análise multivariada e Modelos de
Mudança da paisagem urbana - aplicações na Regional Pampulha -
Belo Horizonte, Minas Gerais - Brasil.**

GRAZIELLE ANJOS CARVALHO

Tese submetida à Banca Examinadora designada pelo Colegiado do Programa de Pós-Graduação em GEOGRAFIA, como requisito para obtenção do grau de Doutor em GEOGRAFIA, área de concentração ANÁLISE AMBIENTAL.

Aprovada em 21 de agosto de 2015, pela banca constituída pelos membros:

Prof(a). Ana Clara Mourao Moura - Orientador
UFMG

Prof(a). Clodoveu Augusto Davis Junior
UFMG

Prof(a). João Paulo Amaral Haddad
UFMG

Prof(a). Ricardo Alexandrino Garcia
UFMG

Prof(a). Michere Campagna
Università Degli Studi di Cagliari, Itália

Prof(a). Elena Massala
SITI/POLITO Politecnico di Torino, Italia

Belo Horizonte, 21 de agosto de 2015.

Dedico este trabalho á todos aqueles que pesquisam, estudam e buscam por melhorias no espaço urbano. E para aqueles que direta ou indiretamente têm sua qualidade de vida influenciados pelas decisões feitas nas grandes cidades.

AGRADECIMENTOS

Agradecer consiste em reconhecer que não é possível chegar até aqui sozinho e que tem pessoas que cruzam nossos caminhos com o intuito de nos ajudar a superar nossas limitações, ter uma visão mais ampla das coisas. É chegado o momento de agradecer publicamente a estas pessoas que me ajudaram nesta caminhada.

Em primeiro lugar gostaria de agradecer aos meus pais, por sempre me incentivarem a buscar algo melhor pra mim e me conscientizar que essa melhora viria única e exclusivamente da educação.

Aos meus amigos pessoais por compreenderem que minha ausência em muitas vezes não era por falta de interesse, mas por falta de tempo mesmo...Mas sobretudo por não desistirem de mim ou da nossa amizade.

Gostaria de agradecer á minha orientadora, Ana Clara Mourão Moura, por confiar e acreditar em mim. Por ter permitido que estes 3,5 anos fossem voltados para atender os meus objetivos como pesquisadora, por ter feito deste tempo um tempo agradável de amadurecimento pessoal e profissional. Por ter me dado todas as condições de desenvolver esta pesquisa, seja na aquisição de software, base de dados, orientações exclusivas ou em grupo. Enfim, por ter mudado a minha vida desde a primeira vez que cruzou o meu caminho.

Junto á Ana Clara, gostaria de agradecer ao grupo de pesquisa carinhosamente denominado “Orientandos da Ana” que é composto por Bráulio Magalhães, Rodrigo Ribas, Júnia Borges, Camila Zynger. Uma equipe que dá prazer e orgulho de trabalhar junto. Cuja produtividade e harmonia é natural. Encontrar com vocês no laboratório foi um dos fatores que me propiciaram terminar essa pesquisa. Obrigado por todas as trocas, obrigado por terem se tornado mais que colegas de trabalho mas amigos que levo pra vida toda.

Agradeço ainda aos professores que cruzaram meu caminho e que com uma dica ou outra me ajudaram a delimitar essa pesquisa: Professor Thiago Carneiro – UFOP, que com uma conversa em Ouro Preto me abriu a mente para o entendimento do processo de modelagem; ao Professor Heinrich Hasenack, do laboratório de Ecologia da UFRS e equipe, onde fizemos um treinamento de uma semana no processo de modelagem usando o IDRISI; aos Professores Monica Haddad e Francis Owusu, do College of Desig, ISU – USA; onde tive a oportunidade

de fazer o estágio sanduíche do doutorado e que me proporcionou uma das experiências mais gratificantes da minha vida; ao amigo Gerson Santos, da UFV, Geostatístico que me deu toques para melhorar o artigo 1 da tese; ao Professor João Haddad e sua aluna de doutorado Camila Oliveira pela disponibilidade em rodar os testes de análise fatorial comigo.

Aos professores Heloisa Costa (IGC), Michele Campagna (Itália) e Piort Jankovisk (USA) que comporam a banca de qualificação e mudaram todo o projeto inicial;

Aos pesquisadores visitantes Elena Masala e Stefano Pensa (Torino – Italia), Michele Campagna (Cagliari - Itália), Piort Jankovisk (San Diego - USA) e Monica Haddad (Iowa – USA) pelas contribuições junto ao grupo de pesquisa de Modelagem Paramétrica da Ocupação Territorial e pelas disciplinas ministradas junto à Escola de Arquitetura, permitindo acesso á novas práticas do planejamento urbano.

Agradeço também aos professores Clodoveu Davis Junior (ICEX – UFMG) e Ricardo Alexandrino Garcia (IGC – UFMG) que contribuíram para a integralização deste trabalho.

Agradeço ao CNPq, pelo apoio através do projeto “Modelagem Paramétrica da Ocupação Territorial: proposição de novos recursos das geotecnologias para representar e planejar o território urbano”, Processo 405664/2013-3, Chamada MCTI/CNPq/MEC/CAPES Nº 43/2013.

Agradeço à bolsa CAPES que favoreceu o desenvolvimento do presente trabalho, seja na etapa no Brasil ou nos EUA.

E por último e não menos importante, agradeço a Deus, que me permitiu chegar até aqui.

Study the past if you would define the future.

Confúcio

RESUMO

A Teoria do Caos ou dos Sistemas Complexos define que um sistema maior é composto por subsistemas menores que funcionam interligados entre si, e que a tentativa de compreender e interferir em um subsistema excluindo a interação entre os demais subsistemas leva o sistema maior ao caos. Baseado neste princípio, apresentamos o Sistema Urbano como um sistema complexo e que portanto deve ser estudado e avaliado à luz de metodologias complexas. Desta forma, este trabalho apresenta como objetivo geral comparar diferentes metodologias – simples e complexas - de seleção de variáveis e modelagem urbana, a fim de entender o comportamento deste objeto à luz dos Modelos de Simulação da paisagem. Para o planejamento urbano, os Modelos de Simulação apresentam-se como ferramentas de apoio no processo de decisão já que estes podem auxiliar na compreensão das dinâmicas que envolvem determinado território, assim como a simulação de cenários de acordo com os interesses dos grupos que detém o poder da decisão no setor de planejamento estratégico. Tais modelos permitem simular e verificar com antecedência a vida útil de determinadas políticas públicas e projetos assim como embasar tecnicamente tais decisões. Este trabalho apresenta quatro artigos de resultados os quais comparam e avaliam métodos de seleção de variáveis para compor o Modelo de Simulação da paisagem urbana da Pampulha, Belo Horizonte – Brasil, através dos métodos de análise multivariada: Análise Fatorial, Monte Carlo, Crámer-Von-Mises e Regressão Logística. Uma vez identificado o método de seleção de variáveis mais eficiente para este processo, e identificadas as variáveis que compõem o modelo, partiu-se para a segunda parte onde se faz comparações entre métodos de modelagem das dinâmicas da cobertura/uso do solo da Pampulha, entre eles: *Exogenous Quantity* e Regressão Linear (Geomod); Cadeia de Markov e Autômatos Celulares (Ca-Markov); e Cadeia de Markov e Redes Neurais (LCM), todos módulos de modelagem dinâmica na plataforma Idrisi/Selva. Diante da avaliação dos resultados, concluímos que o maior desafio para que os Modelos de Simulação se tornem uma ferramenta acessível aos gestores é o banco de dados. Os modelos que apresentaram melhores índices de validação necessitaram de no mínimo 3 mapas de uso/cobertura do solo de tempos distintos e em escala compatível com a dinâmica urbana (muito detalhe). Observa-se entretanto que ainda não existem investimentos na organização e coletas das informações geográficas em formato compatível com o SIG na grande maioria das prefeituras brasileiras. Aconselha-se ainda a presença de um profissional que seja capaz de entender as dinâmicas espaciais no território estudado para que este estruture e identifique com maior agilidade as regras de transição que compõem o modelo de mudança.

Palavras Chaves: Planejamento Urbano, Modelos de Simulação, Análise Multivariada, Pampulha

ABSTRACT

The Chaos or Complex Systems Theory sets that: (i) a larger system is composed by smaller subsystems that are interconnected; (ii) trying to understand and interfere in a subsystem excluding the interaction between other subsystems takes the larger system into chaos. Based on this principle, we present the Urban System as a complex system and therefore should be studied and assessed based on complex methodologies. Thus, this paper presents as a general task to compare different methodologies - simple and complex – concerning variable selection and urban modelling in order to understand the behaviour of urban area based on landscape Simulation Models. For urban planning, the Simulation Models are presented as support tools in decision making processes. It can be useful as a support tools once they can help to understand the dynamics that involve certain territory, as well as they are helpful on scenarios simulation made according with interests of groups that own the power of decision in the strategic planning sector. Such models allow to simulate and verify in advance the useful life of certain public policies and projects as well as they can technically base such decisions. This work presents four papers of results. The first one compare and evaluate variable selection methods to compose the Pampulha Land change model, Belo Horizonte - Brazil, comparing Multivariate analysis composed by Factor Analysis, Monte Carlo, Cramer-Von-Mises and Logistic Regression methods. Identified the most efficient variable selection method for this process and the variables that was used as input in the Land Change Model, the next step was make comparison between methods of Land use/cover dynamics modelling in Pampulha, among them: Exogenous Quantity and Linear Regression (GEOMOD); Markov Chain and Cellular Automata (CA-Markov); and Markov Chain and Neural Networks (LCM), all dynamic modelling modules in IDRISI platform. Considering results evaluation, this investigation concluded that the biggest challenge for Simulation Models becoming a handy tool for managers is the database once models that showed better validation indices required at least 3 maps of use or land cover in different times and in a compatible scale with urban dynamics. However, it is observed that there are still no investment in the organization and collection of geographical information in a type compatible with GIS in most Brazilian municipalities. It also advised the presence of a professional who is able to understand the spatial dynamics in the territory studied to structure and identify more quickly the transition rules that make up the model change.

Keywords: Urban Planning, Simulation Models, Multivariate Analysis, Pampulha

- Figuras:

Figura 1: Vista aérea de Belo Horizonte – MG – Brasil	11
Figura 2: Mancha urbana de Região Metropolitana de São Paulo e Baixada Santista - Brasil	11
Figura 3: A cidade como um sistema complexo.....	12
Figura 4: Feedback em sistemas complexos. Adaptado de Palazzo (2004)	13
Figura 5: Framework for Geodesign - Fonte: STEINITZ (2012).....	17
Figura 6: Parâmetros da Regressão Linear	27
Figura 7: Projeção suavizada e mapa de resíduos da Regressão Múltipla	29
Figura 8: Output das Estatísticas de Regressão múltipla.....	30
Figura 9: Imagem projetada da Pampulha á partir da cobertura do solo de 2011 e os resultados estatísticos da Regressão logística múltipla.....	32
Figura 10: Projeção do uso do solo por Regressão Logística Multinomial e Resultados estatísticos.....	34
Figura 11: Imagens de probabilidade de mudança considerando as tipologias Água e Urbano	35
Figura 12: Imagens de probabilidade de mudança considerando as tipologias Vegetação Densa e Rasteira	35
Figura 13: Redes Neurais – Organização em Camadas. Adaptado de BRAGA et al.,(2000)..	37
Figura 14: Probabilidade Condicional de se tornar ou permanecer como classe 1 de acordo com a Cadeia de Markov.	42
Figura 15: Probabilidade Condicional de se tornar ou permanecer como classe 2 de acordo com a Cadeia de Markov	42
Figura 16: Probabilidade Condicional de se tornar ou permanecer como classe 3 de acordo com a Cadeia de Markov	43
Figura 17: Probabilidade Condicional de se tornar ou permanecer como classe 4 de acordo com a Cadeia de Markov	43
Figura 18: Lógica de funcionamento de um Autômato Celular simples.....	44
Figura 19: Diferentes noção de vizinhança consideradas em Autômato Celular	46
Figura 20: Uso do solo da regional Pampulha/BH projetado usando CA_MARKOV	49
Figura 21: Características dos sistemas multi-agentes	51

Figura 22: Fluxograma do processo de Análise de Mudanças, Modelos de treinamento e Validação no LCM. Adaptado de (Eastman, J. R. 2012b).	55
Figura 23: Mapa de mudanças e permanências do uso do solo.....	56
Figura 24: Mapas de potencial de transição calculados através de Redes Neurais (MLP)	58
Figura 25: Fluxograma do processo de modelagem futura do uso do solo no LCM. Adaptado de (Eastman, J. R. 2012b).....	59
Figura 26: Outputs do LCM - Mapa projetado do uso do solo e mapa síntese de probabilidade de mudança	60
ARTIGO 1	
Figura 1: Variáveis explicativas, sendo: (1a) Acessibilidade e Capilaridade; (1b) Densidade de projetos aprovados na PBH	75
Figura 2: Variáveis explicativas, sendo: (2a) Índice de permissividade em função do zoneamento; (2b) Potencial pela área construída no lote	76
Figura 3: Variáveis explicativas, sendo: (3a) Distância das Operações Urbanas; (b) Densidade de Comércio – mais de 05 centros comerciais por ponto	77
Figura 4: Probabilidade condicional de mudança – (4a) Veg. Densa; (4b) Veg. Rasteira;.....	78
ARTIGO 2	
Figura 1: Validação do Modelo de Simulação da Pampulha no módulo GEOMOD.....	101
Figura 2: Comparação entre o mapa Real e projetado da Pampulha para o ano de 2013	101
Figura 3: Mapa de aptidão às mudanças considerando as variáveis drivers	102
Figura 4a: Mapa projetado da cobertura do solo para 2010; 4b: Mapa de Tornou-se urbano	102
ARTIGO 3	
Figura 1: Localização da área de estudo – Regional Pampulha	109
Figura 2: Fluxograma geral da Modelagem baseada em CA-Markov	113
Figura 3: Fluxograma da etapa Cadeia de Markov	113
Figura 4: Fluxograma CA-Markov, Calibração, Validação.	114
Figura 5: Mapa de cobertura do solo da Regional Pampulha, anos 2009, 2011 e 2013.....	116
Figura 6: Probabilidade de Mudança condicional da tipologia de cobertura do solo: Água e Urbano	116
Figura 7: Probabilidade de Mudança condicional da tipologia de cobertura do solo: Vegetação densa e rasteira.....	117
Figura 8: Índices de validação do modelo CA-Markov	117

Figura 9: Mapas de uso do solo da Pampulha 2013 real e 2020 projetado	118
Figura 10: Gráfico de perdas (roxo) e ganhos (verde) na transformação da cobertura do solo da Regional Pampulha 2013-2020.....	119
Figura 11: Gráfico de contribuidores para as mudanças na cobertura do solo Urbano.....	119
Figura 12: (a) Perdas e ganhos da tipologia Urbano para a Pampulha no ano 2020; (b) área core das transformações na Pampulha – cenário 1	120
Figura 13a: Potencial de transformação de uma nova via de fluxo rápido na Pampulha.....	120
Figura 14: Tendência de mudança através de um algoritmo de 3 ^a ordem.....	121
Figura 15: (a) área core das mudanças cenário 1 (b) área core das mudanças cenário 2	121
Figura 16: Zoneamento Urbanístico da Pampulha – Belo Horizonte - 2010	122
Figura 17: Densidade de centros comerciais na Pampulha – Belo Horizonte.....	123
Figura 18: Potencial de transformação segundo a disponibilidade de lotes vagos e residências de até 1 andar na Pampulha	123
ARTIGO 4	
Figura 1: (a) Projeto de implantação de uma nova via de Fluxo rápido; (b) Potencial de transformação da nova via de fluxo rápido a ser implantada na Regional Pampulha.	132
Figura 2: Fluxograma geral da Modelagem baseada em CA-Markov	133
Figura 3: Fluxograma da etapa Cadeia de Markov	133
Figura 4: Fluxograma da etapa Cellular Automata, Calibração, Validação	134
Figura 5: Fluxograma do processo de Análise de Mudanças, Modelos de treinamento e Validação no LCM. Adaptado de (Eastman, J. R. 2012b)	136
Figura 6: Fluxograma do processo de modelagem futura do uso do solo no LCM. Adaptado de (Eastman, J. R. 2012b).	137
Figura 7: Probabilidade de se tornar urbano - Cenário CA-Markov	138
Figura 8: Potencial de transformação das tipologias de cobertura do solo para urbano no ano 2020	139
Figura 9: Potencial de transformação das tipologias de cobertura do solo para urbano no ano 2020 considerando a implantação de uma via de fluxo rápido na Regional Pampulha	139

CONSIDERAÇÕES FINAIS

Figura 1: Densidade das mudanças projetadas na Regional Pampulha – Modelo de Simulação LCM	141
Figura 2: Densidade das mudanças projetadas na Regional Pampulha – Modelo de Simulação CA-MARKOV	141
Figura 3: Densidade das mudanças projetadas na Regional Pampulha – Modelo de Simulação GEOMOD.....	142

- Tabelas

Tabela 1: Quadro síntese das metodologias de Regressão quanto o tipo de variáveis e suas tipologias	36
Tabela 2: Exemplo de Transition probability matrix – Markov/Idrisi Selva	42
Tabela 3: Exemplo de Transition areas matrix – Markov/Idrisi Selva.....	42
Tabela 4: Comparação entre CA e MSA	51
Tabela 5: Exemplos de aplicações de rotinas de planejamento estratégico	63
Tabela 6: Quadro síntese das principais características dos métodos de Modelos de Simulação	68
ARTIGO 1	
Tabela 1: Relação das bases cartográficas utilizadas no artigo	74
Tabela 2: Índice de acessibilidade e capilaridade por tipologias de vias	74
Tabela 3: Índice de permissividade por zoneamento.....	75
Tabela 4: Exemplo de conjunto de dados de uma análise fatorial.....	79
Tabela 5: Síntese comparativa entre as variáveis explicativas considerando diferentes métodos estatísticos.....	85
Tabela 6: Síntese dos parâmetros de classificação dos resultados	86
Tabela 7: Aplicação dos parâmetros de análise estatística Monte Carlo, Regressão Linear e Cramér-von Mises na seleção de variáveis explicativas	86
Tabela 8: Desempenho do Modelo de Simulação na comparação dos métodos de análise estatística Monte Carlo, Regressão Linear e Cramér-von Mises	87
ARTIGO 2	
Tabela 1: Relação das bases cartográficas utilizadas no artigo	95
Tabela 2: Primeira rodada da Análise fatorial – análise do comportamento das variáveis explicativas disponíveis.....	96
Tabela 3: Primeira rodada da Análise fatorial – Cargas fatoriais e Erro	97
Tabela 4: Segunda rodada da Análise fatorial – análise do comportamento das variáveis explicativas selecionadas.....	97
Tabela 5: Segunda rodada da Análise fatorial – Cargas fatoriais e Erro	97
Tabela 6: Análise fatorial	98
ARTIGO 3	
Tabela 1: Matriz de probabilidade de transição de áreas.....	117

ARTIGO 4

Tabela 1: Relação das bases cartográficas utilizadas no artigo	131
--	-----

- Fórmulas:

Equação 1	26
Equação 2	28
Equação 3	31
Equação 4	33
Equação 5	34
Equação 6	38
Equação 7	38
Equação 8	39
Equação 9	40
ARTIGO 1	
Equação 1	73
Equação 2	78
Equação 3	79
Equação 4	80
Equação 5	83
ARTIGO 3	
Equação 1	111

- Lista de abreviaturas e siglas

AC - Autômato Celular

CA - Cellular Automata

GIS - Geographic information system

LCM - Land Change Models

MBA - Modelagem Baseada em Agentes

MBI - Modelagem Baseada em Indivíduos

MLP - Multi-Layer Perceptron neural network classifier

PSS - Planning Support System

RNA - Redes Neurais Artificiais

SIG - Sistemas de Informação Geográfica

SMA - Sistema Multiagente

UNB - Universidade de Brasília

Sumário

FICHA CATALOGRÁFICA	
DEDICATÓRIA.....	I
AGRADECIMENTOS	II
RESUMO	V
ABSTRACT	VI
– FIGURAS:.....	VII
– TABELAS	XI
– FÓRMULAS:	XIII
– LISTA DE ABREVIATURAS E SIGLAS	XIV
INTRODUÇÃO.....	1
1.SISTEMAS COMPLEXOS.....	4
1.1 CARACTERÍSTICAS DOS SISTEMAS COMPLEXOS.....	6
1.2 A CIDADE COMO UM SISTEMA COMPLEXO	9
2. MODELAGEM DINÂMICA DA PAISAGEM URBANA: APLICAÇÕES E DESAFIOS	15
2.1 MODELOS DE SIMULAÇÃO COMO FERRAMENTA DE APOIO Á COMPREENSÃO DOS PADRÕES E PROCESSOS NA CONFIGURAÇÃO DA PAISAGEM.....	18
2.2 TIPOS DE DADOS USADOS NOS MODELOS DE SIMULAÇÃO	21
2.3 MODELOS DE SIMULAÇÃO: REGRAS DE TRANSIÇÃO E METODOLOGIAS	24
2.3.1 MÉTODOS DE AUTO - APRENDIZAGEM E METODOLOGIAS DE PROJEÇÃO BASEADA EM “ <i>EXOGENOUS QUANTITY</i> ” E “ <i>MACHINE LEARNING</i> ”	25
2.3.1.1 MÉTODOS ESTATÍSTICOS DE ESTIMAÇÃO - REGRESSÃO LINEAR SIMPLES E MÚLTIPLA, REGRESSÃO LOGÍSTICA SIMPLES, MÚLTIPLA E MULTINOMIAL.....	26
2.3.1.2 MÉTODOS ESTATÍSTICOS DE ESTIMAÇÃO - REDES NEURAIIS.....	36
2.3.2 METODOLOGIA DE PROJEÇÃO DO USO DO SOLO BASEADA EM MARKOV CHAIN E CELLULAR AUTOMATA	40
2.3.2.1 MARKOV CHAIN.....	40

2.3.2.2 CELLULAR AUTOMATA.....	43
2.3.2.3 AGENT-BASED MODEL – MODELAGEM BASEADO EM AGENTES.....	49
2.3.2.4O LAND CHANGE MODELER (LCM) FOR ECOLOGICAL SUSTAINABILITY – UM MODELO DE SIMULAÇÃO DA PAISAGEM PARA SUSTENTABILIDADE ECOLÓGICA.....	54
2.3.2.5 ROTINAS DE PLANEJAMENTO ESTRATÉGICO.....	60
2.4 CALIBRAÇÃO E VALIDAÇÃO.....	64
3. RESULTADOS.....	69
ARTIGO 01: COMPARAÇÃO ENTRE MÉTODOS DE ANÁLISE MULTIVARIADA NA SELEÇÃO DE VARIÁVEIS EXPLICATIVAS PARA COMPOR UM MODELO DE SIMULAÇÃO DA PAISAGEM – APLICAÇÕES NA PAMPULHA, BRASIL.....	71
ARTIGO 02: MODELO DE SIMULAÇÃO DA PAISAGEM URBANA DA PAMPULHA INTEGRANDO METODOLOGIAS DE ANÁLISE FATORIAL, ANÁLISE DE MULTICRITÉRIO E <i>EXOGENOUS QUANTITY</i> NO MÓDULO GEOMOD/IDRISI.....	92
ARTIGO 03: CONSTRUÇÃO DE CENÁRIOS PARA A REGIONAL PAMPULHA POR CADEIA DE MARKOV E AUTÔMATOS CELULAR: PROJEÇÃO DAS ALTERAÇÕES NA COBERTURA DO SOLO.....	106
ARTIGO 04: COMPARAÇÃO DOS MÉTODOS “ <i>WHAT IF / IF THEN</i> ” POR AUTÔMATO CELULAR E REDES NEURAIAS: SIMULAÇÃO DE CENÁRIOS FUTUROS DA REGIONAL PAMPULHA CONSIDERANDO A IMPLANTAÇÃO DE UMA NOVA VIA DE FLUXO RÁPIDO.....	128
CONSIDERAÇÕES FINAIS.....	142
REFERÊNCIAS.....	146

INTRODUÇÃO

O Brasil, já na década de 1970, tornou-se um país predominantemente urbano, vindo a alcançar o percentual de 84% no ano de 2010 (IBGE, 2010). Diante deste cenário, é cada vez maior a necessidade de se obter um novo olhar para se pensar e fazer o Planejamento Urbano no Brasil.

Com a maior concentração de pessoas e serviços neste ambiente, tem-se observado a intensificação dos chamados “Problemas urbanos”, tais como as questões relacionadas a mobilidade, acessibilidade, moradia, educação, saúde, acesso á infra-estrutura urbana, serviços, segurança, lazer, enfim, condições estas e outras que não têm sido atendidas de forma satisfatória nos grandes centros por não serem pensadas como variáveis integrantes de um mesmo sistema, mas por até agora serem pensadas de forma isolada e desconectas. Assim, faz-se necessário compreender como estes interagem entre si, no tempo e no espaço e como influenciam o/no sistema.

Uma das metodologias que se têm destacado no cenário internacional para estudos que envolvem as dinâmicas urbanas refere-se ao uso dos Modelos de Simulação da paisagem (*Land Change Models*). Estes constituem-se como uma das mais avançadas técnicas para responder as necessidades e interesses das investigações acerca de dinâmicas de uso/cobertura do solo urbano e regional (Almeida, Monteiro & Câmara, 2007:278). Estudos têm sido feito e apresentado resultados que auxiliam no planejamento regional e local por meio da construção de cenários futuros, levando o gestor à simulação em ambiente computacional de sua ação, possibilitando mapear e identificar os impactos que a mesma causará antes da sua implementação. Entretanto, existe uma infinidade de métodos que nos permitem projetar ou simular tais cenários e inúmeras dúvidas que pairam sobre este processos:

- Como funciona o processo de simulação e projeção de cenários futuros para uso/cobertura do solo urbano?
- Quais as diferenças entre os métodos mais usados?
- Quais as restrições destes métodos?
- Quais os desafios que temos no cenário nacional ao aplicar essa metodologia como ferramenta de apoio ao processo de tomada de decisões no Planejamento urbano?

Desta forma, este trabalho apresenta como objetivo geral comparar diferentes metodologias de modelagem urbana e assim apresentar as vantagens e limitações de cada método. Para tal, foi definido a área da Regional Pampulha como estudo de caso e todas as metodologias aqui apresentadas serão aplicadas neste local, favorecendo assim a comparação.

Como objetivos específicos, almejamos:

- Apresentar o Sistema urbano como um Sistema Complexo
- Apresentar os requisitos necessários para a Modelagem para projeção e simulação de cenários, sobretudo para o ambiente urbano;
- Apresentar e comparar os métodos de seleção de variáveis: Análise Fatorial, Monte Carlo, Cramer Von-Mises e Regressão Logística
- Apresentar e comparar os métodos de projeção: *Exogenous Quantity*, Regressão, Cadeia de Markov, Autômato Celular e Redes Neurais, assim como o uso destes na construção de rotinas de planejamento estratégico que visem a simulação de cenários e projeção da cobertura do solo,
- Apresentar as possibilidades de aplicações e restrições de tais técnicas no Planejamento urbano;

Assim, esta Tese apresentará, em um primeiro momento, o estado da arte da Teoria dos Sistemas Complexos, assim como as características que fazem do sistema urbano um sistema complexo.

Em sequência, apresentamos uma revisão bibliográfica sobre “*Modelagem Dinâmica da Paisagem Urbano: desafios e aplicações*”. Neste capítulo avaliamos os “*Modelos de Simulação como ferramenta de apoio à compreensão dos padrões e processos na configuração da Paisagem*” onde relatamos os tipos, formatos, configurações e padrões que os dados devem apresentar para serem usados nos Modelos de Simulação. Em “*Modelos de Simulação: algoritmos e metodologias*” os métodos de *Exogenous Quantity*, Regressão, Cadeia de Markov, Autômato Celular e Redes Neurais são apresentados, assim como alguns exemplos de plataformas GIS onde estes métodos são encontrados. Também apresentamos o conceito de *Planning Support System* e Rotinas de Planejamento Estratégico. Em “*Calibração e Validação*”, caracterizamos estes processos assim como apresentamos alguns índices mais

comumente usados. Em cada seção são apresentados exemplos nacionais e internacionais de aplicações dos Modelos de Simulação.

Como resultados, apresentamos 04 (quatro) artigos que estruturam-se da seguinte maneira:

- Artigo 01: Comparação entre métodos de análise multivariada na seleção de variáveis explicativas para compor um Modelo de Simulação da Paisagem – Aplicações na Pampulha, Brasil
- Artigo 02: Modelo de Simulação da Paisagem Urbana da Pampulha integrando metodologias de Análise Fatorial, Análise de Multicritério e Exogenous quantity no módulo Geomod/Idrisi
- Artigo 03: Construção de Cenários para a Regional Pampulha por Cadeia de Markov e Autômatos Celular: projeção das alterações na cobertura do solo
- Artigo 04: Comparação dos métodos “*What if / If then*” por Cadeia de Markov, Autômato Celular e Redes Neurais: simulação de cenários futuros da Regional Pampulha considerando a implantação de uma nova via de fluxo rápido

Esta tese não possui um capítulo específico de metodologia uma vez que esta será apresentada em um eixo específico, dentro de cada artigo. As “*Considerações Finais*” aparece na sequência onde realizamos uma análise comparativa dos Métodos de modelagem aplicados á Pampulha, assim como a indicação de possibilidades de usos e desafios a serem superados ao adotarmos essa técnica como uma ferramenta de apoio ao Planejamento Urbano no Brasil. Em seguida, as Referências bibliográficas.

1. SISTEMAS COMPLEXOS¹

A física clássica de Isaac Newton, até o século XIX, estabelecia uma exata correspondência entre causa e efeito. Os cientistas tinham certeza de serem capazes de reduzir até as mais complicadas situações e interações em simples e poucas leis e, assim, prever o comportamento dos mais complexos sistemas ao longo do tempo.

Segundo Capra (1982), neste período chegamos à concepção do universo como um sistema mecânico que consiste em objetos separados, os quais, por sua vez, foram reduzidos a seus componentes materiais fundamentais cujas propriedades e interações determinavam completamente todos os fenômenos naturais. Essa concepção cartesiana da natureza foi estendida aos organismos vivos, considerados máquinas constituídas por peças separadas.

A concepção mecanicista do funcionamento do planeta Terra ainda está na base da maioria das ciências e continua a exercer uma enorme influência em muitos aspectos da vida contemporânea. Esta levou à fragmentação do conhecimento e na percepção de que não se precisa ter o conhecimento das interações entre os sistemas para resolver os problemas nele contido. É como se o mundo fosse formado por peças separadas e desconectadas a serem exploradas por diferentes grupos de interesses.

A crença segundo a qual em todo sistema complexo o comportamento do todo pode ser entendido inteiramente a partir das propriedades de suas partes é fundamental no paradigma cartesiano (CAPRA, 1996).

No início do século XX, quando os físicos estenderam o alcance de suas investigações aos domínios dos fenômenos atômicos e subatômicos, tomaram subitamente consciência das limitações de suas ideias clássicas e tiveram que rever radicalmente muitos de seus conceitos básicos acerca da realidade.

O grande impacto que adveio com a ciência do século XX foi a percepção de que os sistemas não podem ser entendidos pela análise. As propriedades das partes não são propriedades intrínsecas, mas só podem ser entendidas dentro do contexto do todo mais amplo. Desse modo, a relação entre as partes e o todo foi revertida. Na abordagem sistêmica, as propriedades das partes podem ser entendidas apenas a partir da organização do todo. Em

¹ As referências bibliográficas deste capítulo se encontram na sessão “Referências” após as Considerações Finais da Tese.

conseqüência disso, o pensamento sistêmico concentra-se não em blocos de construção básicos, mas em princípios de organização básicos. O pensamento sistêmico é "contextual", o que é o oposto do pensamento analítico. A análise significa isolar alguma coisa a fim de entendê-la; o pensamento sistêmico significa colocá-la no contexto de um todo mais amplo (CAPRA, 1996).

A descoberta da evolução na geologia e biologia forçou os cientistas a abandonarem a concepção analítica segundo a qual o mundo era uma máquina inteiramente construída pelas mãos do Criador. Duas descobertas no campo da física, culminando na teoria da relatividade e na Teoria Quântica, pulverizaram todos os principais conceitos da visão de mundo analítico-cartesiano e da mecânica newtoniana. Segundo Capra (1982), a noção de espaço e tempo absolutos, as partículas sólidas elementares, a substância material fundamental, a natureza estritamente causal dos fenômenos físicos e a descrição objetiva da natureza são conceitos que não podem ser estendidos aos novos domínios em que a física atuava. O universo deixa de ser visto como uma máquina, composta de uma infinidade de objetos, para ser descrito como um todo dinâmico, indivisível e cujas partes estão essencialmente inter-relacionadas.

"O mundo apresenta-se, pois, como um complicado tecido de eventos, no qual conexões de diferentes espécies se alternam, se sobrepõem ou se combinam e desse modo determinam a textura do todo" (GARBER, 1978).

Para Capra esta teoria se configura como uma nova linguagem voltada para o entendimento dos sistemas da vida, complexos e altamente integrativos. Cada cientista deu a ela um nome diferente — "teoria dos sistemas dinâmicos", "teoria da complexidade", "dinâmica não-linear", "dinâmica de rede", e assim por diante. Atratores caóticos, fractais, estruturas dissipativas, auto-organização e redes autopoieticas são algumas de suas concepções-chave (CAPRA, 1996).

(...) em sua definição científica, o Caos não significa desordem absoluta ou uma perda completa da forma. Ele significa que sistemas guiados por certos tipos de leis perfeitamente ordenadas são capazes de se comportar de uma maneira aleatória e, desta forma, completamente imprevisível no longo prazo, em um nível específico. Por outro lado este comportamento aleatório também apresenta um padrão ou ordem 'escondida' em um nível mais geral (...). O Caos é a variedade individual criativa dentro de um padrão geral de similaridade STACEY (1991):

Para Paiva (2001), o objeto de estudo da Teoria do Caos é o comportamento dos sistemas de feedback não-lineares como, por exemplo, uma célula, um fenômeno meteorológico, uma empresa, a sociedade, a cidade. Um dos conceitos-chave desta teoria é a demonstração da impossibilidade de se fazer previsões que não sejam no curto prazo, pois o comportamento

desses sistemas dinâmicos é extremamente sensível às suas condições iniciais tanto internas quanto externas.

Para Palazzo (2004), um sistema complexo não pode ser analisado ou separado em um conjunto de elementos independentes sem ser destruído. Conseqüentemente, não é possível empregar métodos reducionistas para a sua interpretação ou entendimento. Se um determinado domínio é complexo, ele será, por definição, resistente à análise. Sendo assim, um importante aspecto das entidades complexas é o fato de elas serem compostas de partes distintas, mesmo que essas partes se encontrem em estreito relacionamento. Portanto, na construção de uma ciência da complexidade deve-se buscar uma visão capaz de transcender a polarização entre holismo e reducionismo, permitindo a modelagem de sistemas que apresentam simultaneamente a característica da distinção (sendo, portanto, separáveis do todo em uma forma abstrata) e da conexão (sendo, portanto, indissociáveis do todo sem a perda de parte do significado original).

1.1 CARACTERÍSTICAS DOS SISTEMAS COMPLEXOS

Para Capra (1996), de acordo com a visão sistêmica, as propriedades essenciais de um organismo ou sistema, são propriedades do todo, que nenhuma das partes possui. Elas surgem das interações e das relações entre as partes. Essas propriedades são destruídas quando o sistema é dissecado, física ou teoricamente, em elementos isolados. Embora se possa discernir partes individuais em qualquer sistema, essas partes não são isoladas, e a natureza do todo é sempre diferente da mera soma de suas partes.

Para Oliveira (2008), sistemas complexos são sistemas formados por muitas unidades simples, porém interligadas entre si, de forma que uma exerce influência no comportamento das outras. A complexidade do todo decorre desse entrelaçamento de influências mútuas, à medida que o sistema evolui dinamicamente. São algumas das características encontradas em maior ou menor grau nos chamados sistemas complexos:

- É um *sistema dinâmico*, em evolução constante, formado de um grande número de unidades (CAPRA, 1996, PALLAZO, 2004; NUSSENZVEIG, 2008; OLIVEIRA, 2008, BATTY, 2012)

Isto significa que certas partes ou estruturas do sistema serão conservadas durante certa evolução de tempo enquanto que outras irão se modificar. Até aqui esta descrição parece bastante trivial: uma parte do sistema se

modifica enquanto que outra permanece sem modificações. É necessário, entretanto algum método para identificar quais os subsistemas que irão mudar e quais os que irão permanecer inalterados (PALAZZO, 2004)

- Cada unidade interage com um número bem menor de outras unidades. O sistema é aberto, interagindo com o meio (GARBER, 1978; CAPRA, 1996, PALLAZO, 2004; NUSSENZVEIG, 2008; OLIVEIRA, 2008, BATTY, 2012).

No estudo da complexidade, entretanto, sem fazer uma distinção a priori entre um sistema e seu ambiente externo não é possível empregar tal critério. A distinção entre o sistema que tenta sobreviver e seu ambiente, que pode permitir ou dificultar esta sobrevivência, é por si só uma característica dos sistemas complexos em geral (PALAZZO, 2004)

- Cada unidade produz uma resposta aos sinais que recebe das outras. Mas essas respostas não guardam uma simples relação de proporcionalidade ao estímulo recebido, ou seja, o sistema é não-linear. As respostas estão condicionadas ao estado inicial do sistema. (CAPRA, 1996, PALLAZO, 2004; NUSSENZVEIG, 2008, BATTY, 2012).

Um fator que contribui para a imprevisibilidade é a sensibilidade às condições iniciais. Um desvio muito pequeno dessas condições é amplificado exponencialmente pela evolução do sistema, produzindo um resultado muito diferente. É o que tende a acontecer na previsão do tempo a longo prazo. (NUSSENZVEIG, 2008)

- *Frustração:* considerando que os sinais recebidos de unidades diferentes podem ser contraditórios, não é possível satisfazer a todos ao mesmo tempo. A resposta frustrará algumas das entradas, dando respostas diferentes ao longo do tempo de acordo com as condições iniciais e as relações de vizinhança apresentadas (CAPRA, 1996, PALLAZO, 2004; NUSSENZVEIG, 2008; OLIVEIRA, 2008, BATTY, 2012).
- *Aprendizado:* O sistema é adaptativo em sua evolução constante, haja vista que a arquitetura básica do sistema vai mudando à medida que ele evolui e interage com o meio.

O comportamento espaço-temporal típico desses sistemas contém fortes correlações entre pontos distantes e entre o presente e a história passada (ou seja, memória, ao contrário dos sistemas chamados markovianos). Num estado crítico auto-organizado, qualquer perturbação pode provocar respostas de qualquer tamanho. Essas respostas seriam responsáveis pela introdução das correlações em todas as escalas. (NUSSENZVEIG, 2008)

- *Ordem emergente*: O sistema se auto-organiza de forma espontânea, criando ordem a partir de um estado desordenado (CAPRA, 1996, NUSSENZVEIG, 2008, BATTY, 2012).

A emergência de uma nova e poderosa concepção, a de auto-organização, se dá, em primeiro lugar, através da compreensão da importância do padrão. A ideia de um padrão de organização consiste na configuração de relações característica de um sistema em particular, ou seja, na configuração de relações. Os padrões, no entanto, não podem ser medidos nem pesados; eles devem ser mapeados. Para entender um padrão, temos de mapear uma configuração de relações. (CAPRA, 1996).

- *O sistema é hierárquico*: (NUSSENZVEIG, 2008, PALAZZO, 2004; BATTY, 2012).

“As interações em pequena escala produzem as estruturas em grande escala as quais por sua vez modificam a atividade na pequena escala.” (PALAZZO, 2004)

- *Estrutura fractal*: estrutura geométrica de auto similaridade em todas as escalas, ou seja, se uma das ramificações da figura for ampliada vê-se que ela, por sua vez, se ramifica em escalas cada vez mais finas (NUSSENZVEIG, 2008, BATTY E LONGLEY, 1994, BATTY, 2012).

In the 1980s, onto this canvas came ideas about how modular patterns in cities were structured and using ideas about self-similar processes of development, cities began to be interpreted as fractal structures (BATTY & LONGLEY, 1994)

- *Retroalimentação*: o sistema se retroalimenta

Em sistemas não-lineares, pequenas mudanças podem ter efeitos dramáticos, pois podem ser amplificadas repetidamente por meio de realimentação de auto-reforço. Esses processos de realimentação não-lineares constituem a base das instabilidades e da súbita emergência de novas formas de ordem, tão típicas da auto-organização. (CAPRA, 1996)

Os sistemas complexos são sistemas **dinâmicos** (mudam com o passar do tempo) e **abertos** (sofrem influência de agentes externos). São formados por **subsistemas** que interagem entre si (redes), através de suas **relações de vizinhanças** (autômatos celulares). Desta forma, toda e qualquer tentativa de previsão nestes sistemas estão condicionadas ao seu **estado inicial** e pequenas alterações podem provocar mudanças significativas em sua estrutura global, uma vez que atuam de maneira **não linear**.

São sistemas **adaptativos**, ou seja, aprendem com os eventos passados, e se **retroalimentam**. Além disso, têm a capacidade de se **auto-organizarem** de forma espontânea, criando **padrões**

geométricos (fractais) onde antes não havia. O sistema é constituído por interações que obedecem a uma **hierarquia**, uma vez que é constituído principalmente por fluxos que interagem.

1.2 A CIDADE COMO UM SISTEMA COMPLEXO

O ambiente urbano configura-se como um sistema complexo, e por isto deve ser tratado e trabalhado com as metodologias que permitam caracterizá-lo segundo teorias e conceitos de redes, fractais e autômatos celulares.

As cidades são construídas por ações individuais e se refletem no espaço de forma coletiva, criando padrões de organização, os quais podem ser identificados por alguns modelos voltados para o estudo das dinâmicas espaciais. Através desta compreensão, vem surgindo uma nova forma de se fazer a gestão e planejamento das cidades, baseada nas teorias da complexidade, posto que não é mais possível abrir mão da concepção de interação dinâmica (espaço-temporal) para ajudar neste processo.

As cidades apresentam padrões espaciais (fractais), fluxos de interações (redes), relações de vizinhança e áreas de influência dos fenômenos (autômatos celulares) que podem ser mapeados, identificados e devem ser considerados na estruturação do modelo geral da dinâmica espacial, considerando o fator escala. Sendo assim, o urbano apresenta inúmeras das características dos sistemas complexos, a saber:

- **É um sistema dinâmico:** As cidades mudam a todo o momento e em um ritmo acelerado. Seja na implantação de infraestruturas, na configuração de sua paisagem, na dinâmica da ocupação territorial, ou nos manifestos sociais e culturais. Além disso, mudam-se seus gestores, e com eles as prioridades de investimentos, o que a torna dinâmica em ambos os sentidos: físico e sociopolítico.

- **É um sistema aberto:** As cidades (escala local) sofrem influência em sua economia, meio ambiente e políticas públicas, entre outros aspectos, das esferas Estaduais, Federal, e/ou até internacional (escala global). Um exemplo de influência externa é o fato de que muitas cidades importam modelos de gestão de outras cidades, como por exemplo, no Brasil, o Rio de Janeiro, Belo Horizonte, Brasília, Goiás, etc. Outro exemplo é o impacto que as cidades sofrem relacionado às ações de seus vizinhos, sobretudo em áreas limítrofes ou a nível de

bacias hidrográficas, já que as decisões tomadas em um município influencia diretamente na forma de gestão dos vizinhos limítrofes.

Num sistema social, cada unidade deve afirmar sua individualidade a fim de manter a ordem estratificada do sistema, mas também deve submeter-se às exigências do todo a fim de tornar o sistema viável. Essas duas tendências são opostas mas complementares. Num sistema saudável — um indivíduo, uma sociedade ou um ecossistema — existe equilíbrio entre integração e auto-afirmação. Esse equilíbrio não é estático, mas consiste numa interação dinâmica entre duas tendências complementares, o que torna todo o sistema flexível e aberto à mudança. (CAPRA, 1982)

- **As cidades são e possuem subsistemas.** Embora tenham sua individualidade, os subsistemas (segurança, educação, saúde, transporte, meio ambiente, entre outros) não devem ser trabalhados de forma individual, mas considerando as interrelações que fazem a soma dos subsistemas comporem um sistema maior e mais complexo.

The various processes that bring people together to produce and exchange goods and ideas that take place in cities define a multitude of networks that enable populations to deliver materials and information to support such endeavours. Physical and social networks tend to mutually reinforce one another as they develop. (BATTY, 2012)

- **Comportamento não-linear:** As cidades apresentam comportamento não linear em sua dinâmica e é por isso que podemos afirmar que nenhuma cidade é igual á outra. O fato das cidades reagirem de forma particular aos diferentes fatores a que são expostas, devido ás suas configurações políticas, socioeconômicas, ambientais e culturais é que as tornam sistemas únicos, embora conectados aos seus vizinhos. O fato de reagirem de forma não linear aos agentes á que são expostos dificulta o processo de predição de seu comportamento.

No entanto, isto não significa que na teoria do caos não sejamos capazes de quaisquer previsões. Ainda podemos fazer previsões muito precisas, mas elas se referem às características qualitativas do comportamento do sistema e não aos valores precisos de suas variáveis num determinado instante. Assim, a nova matemática representa uma mudança da quantidade para a qualidade, o que é característico do pensamento sistêmico em geral. Enquanto a matemática convencional lida com quantidades e com fórmulas, a teoria dos sistemas dinâmicos lida com qualidades e com padrões (CAPRA, 1996)

- **As cidades são sistemas adaptativos,** ou seja, aprendem com os eventos passados. Sofrem influência direta no hoje do que foi feito no ontem, sobretudo na esfera estrutural e política. Embora sejam capazes de se adaptarem às novas demandas e usos.

- **As cidades são auto-organizadas**, criam um padrão geométrico de distribuição do fenômeno facilmente identificável (Fig. 01 e 02). O padrão de ocupação das cidades no meio ambiente é diferente de tudo o mais na natureza. É densamente concentrado, agrupado e impactante nas diversas escalas de estudo.



Figura 1: Vista aérea de Belo Horizonte – MG – Brasil
Fonte: NASA



Figura 2: Mancha urbana de Região Metropolitana de São Paulo e Baixada Santista - Brasil
Fonte: NASA

As cidades são constituídas por interações que obedecem a uma hierarquia, uma vez que são constituídas principalmente por fluxos (redes de mercadorias, pessoas, serviços, informação, cultura) que interagem no espaço obedecendo aos padrões geométricos da ocupação humana e suas relações de vizinhança/proximidade e que se retroalimentam, apresentando-se assim como um sistema complexo (Fig. 03).

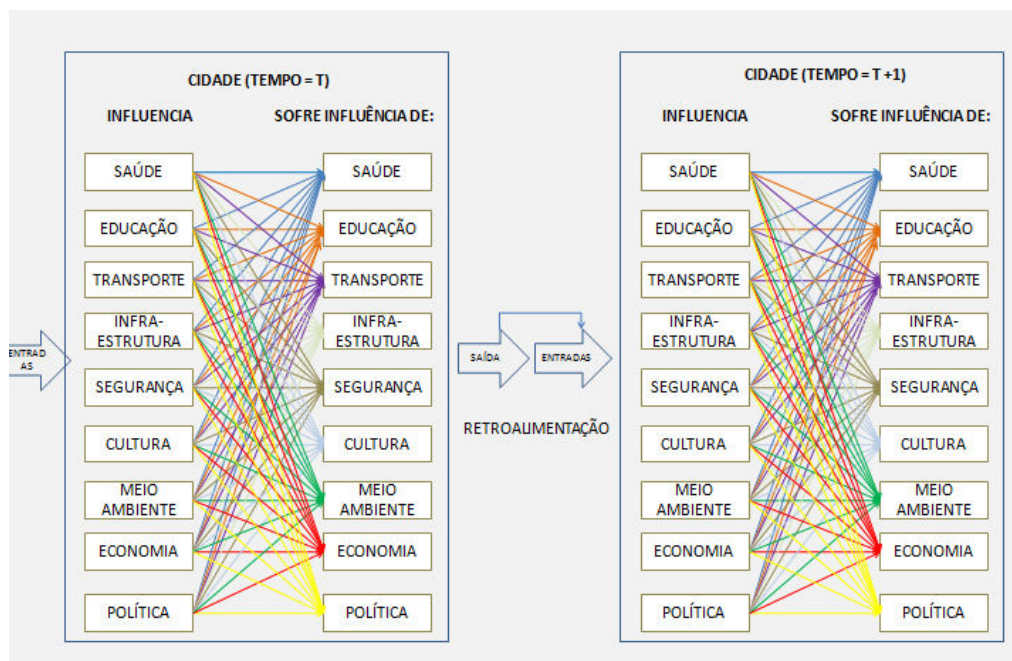


Figura 3: A cidade como um sistema complexo.

A concepção de que a cidade funciona como “entidades distintas” que interagem e que, portanto, podem ser controladas, resultou, por muito tempo, na concepção de que a cidade poderia ser tratada/planejada através de uma gestão centralizadora, "top down", ou de "cima para baixo", ignorando completamente as relações de vizinhança intra e entre cidades e ambiente.

A abordagem top-down viola dois princípios básicos dos fenômenos populacionais, que são a individualidade e a localidade. A individualidade tenta levar em conta as diferenças entre os indivíduos. Tais diferenças, ainda que muito pequenas, podem conduzir a resultados radicalmente diferentes na evolução das populações ao longo do tempo. Por localidade pretende-se significar que cada evento possui uma localização e um escopo de influência. Ignorar a localidade dos eventos obscurece fatores que poderiam contribuir para uma visão mais clara da dinâmica espaço-temporal dos sistemas (KAWATA, 1994; PALAZZO, 2004).

Na verdade, a cidade é o resultado de milhares de decisões individuais e coletivas, tomadas de "baixo para cima" ou “*bottom up*” e, eventualmente, de "cima para baixo" ou “*top down*” (Fig. 04). Portanto, a cidade não pode ser compreendida como um sistema fechado em si, pois esta concepção as fazem denegrir como sistema, onde o desequilíbrio se torna uma constante.

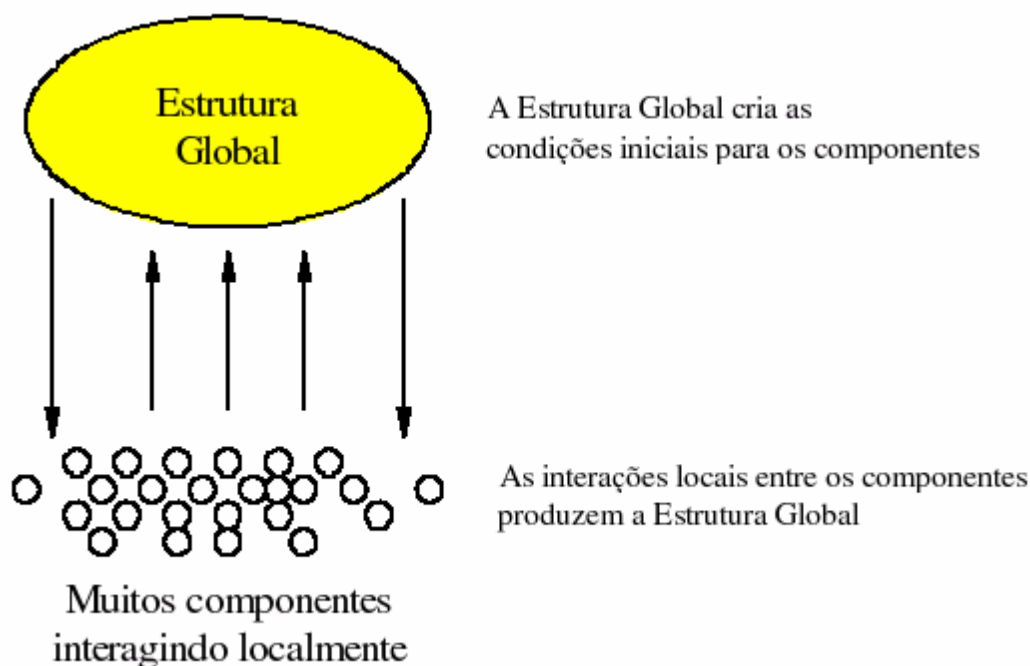


Figura 4: Feedback em sistemas complexos. Adaptado de Palazzo (2004)

Como o diagrama da Figura 04 sugere, há um relacionamento circular entre a estrutura global do sistema e as interações locais entre os componentes. A estrutura global pode ser definida como a rede de todos os relacionamentos locais, que é produzida e mantida em um dado momento pelo total de interações que ocorrem neste momento. Cada um, e ao mesmo tempo todos os componentes do sistema, interagem com seus vizinhos imediatos, modificando assim a estrutura global. Uma vez que cada componente responde à estrutura global, então o comportamento de cada indivíduo é determinado pelo todo. Ao mesmo tempo a resposta independente de todos os componentes em um dado momento produz o todo do momento seguinte. Desta forma, a cidade configura-se como um exemplo de sistema complexo, assim como a sociedade.

Uma cidade e/ou sociedade consiste em muitos componentes independentes interagindo localmente. O estado corrente da cidade e/ou sociedade é a estrutura global. Cada um e todos os indivíduos respondem ao estado corrente e, portanto, criam o novo estado da cidade e/ou sociedade no momento seguinte e assim por diante. Assim, um sistema complexo pode ser definido como sendo constituído por muitos componentes independentes que interagem localmente produzindo um comportamento geral organizado e bem definido independente da estrutura interna dos componentes (PALAZZO 2004).

A percepção das cidades como sistemas se aproxima mais comparativamente aos sistemas biológicos (nos quais todos os componentes estão conectados e influenciam uns aos outros) do que aos sistemas mecânicos (nos quais para se resolver um problema, basta identificar a peça defeituosa e tratá-la separadamente). Mas ainda assim, pensando de forma sistêmica, sob o viés biológico, deve-se ter em mente que a cidade não apresenta esse comportamento em sua totalidade: nos sistemas biológicos, quando um determinado componente o leva ao desequilíbrio, o sistema se reorganizará e tentará retornar ao estado anterior, ou o mais próximo dele. Com cidades isso não acontece: muito pelo contrário, as cidades são sistemas em constantes evoluções e estão muito longe do equilíbrio. Segundo Batty (2012), *“Cities admit innovation, indeed they are the crucibles of innovation, they generate surprise, they display catastrophes”*.

As cidades apresentam respostas diferenciadas às condições iniciais, dependendo da sua forma, tamanho, densidade, estrutura física, ou cenário socioeconômico. Desta forma, pode-se dizer que as cidades, como sistemas complexos, apresentam comportamento não-linear, e que embora uma ação externa possa provocar feedbacks positivos em determinadas cidades, podem provocar feedbacks negativos em outras.

As cidades estão crescendo e, com elas, a quantidade e qualidade das informações que permitem melhor entendê-las. Diante das novas possibilidades tecnológicas, é necessário olhar para as cidades por novos ângulos, através da ação conjunta de diferentes profissionais e agentes sociais. O planejamento das cidades usando os modelos como ferramentas que ajudam a entender a dinâmica das mesmas, seus padrões e regras de comportamento, constitui um campo importante de investigação. O emprego dos conhecimentos obtidos permitirá estabelecer metas conjuntas para se alcançar a cidade desejada, com melhor qualidade de vida para todos os cidadãos.

A consideração e o emprego de teorias alternativas ao pensamento tradicional mecanicista é mais uma opção oferecida aos gestores para um melhor entendimento dos sistemas dinâmicos complexos como o urbano.

2. MODELAGEM DINÂMICA DA PAISAGEM URBANA: APLICAÇÕES E DESAFIOS²

A teoria dos Sistemas baseia-se no princípio da interação entre estrutura e comportamento.

Once we see the relationship between structure and behavior, we can begin to understand how systems work, what makes them produce poor results, and how to shift them into better behavior patterns. As our world continues to change rapidly and become more complex, systems thinking will help us manage, adapt, and see the wide range of choices we have before us. It is a way of thinking that gives us the freedom to identify root causes of problems and see new opportunities (MEADOWS, 2008).

Os agentes de cada sistema apresentam um padrão de comportamento ao longo do tempo e este padrão faz com que as forças que integram o sistema atuem de forma única em cada agente, e conseqüentemente, faz com que este responda á essas forças também de forma única.

The system, to a large extent, causes its own behavior! An outside event may unleash that behavior, but the same outside event applied to a different system is likely to produce a different result (MEADOWS, 2008).

A busca pela compreensão de como estes sistemas funcionam e a tentativa de um melhor aproveitamento dos mesmos levou a humanidade ao seu atual estágio evolutivo como espécie.

Research provides in the first instance better understanding of how things are and how they work, which can then contribute to the improvement or optimization of these systems through the development of new techniques, processes, materials and protocols (MULLIGAN & WAINWRIGHT, 2004).

O desenvolvimento de novas técnicas computacionais, o maior domínio da matemática e estatística assim como uma melhor compreensão dos processos socioeconômicos na sociedade permitiu que alguns estudiosos descrevessem a sociedade e o ambiente através de modelos.

Segundo Haggett & Chorley (1967;1975), modelo pode ser entendido como uma estruturação simplificada da realidade que supostamente apresenta, de forma generalizada, características ou relações importantes. Para Christofolletti (1999), modelo ainda pode ser compreendido

² As referências bibliográficas deste capítulo se encontram na sessão “Referências” após as Considerações Finais da Tese

como um aspecto do mundo real que surja como de interesse do pesquisador, que possibilite reconstruir a realidade, prever um comportamento, uma transformação, ou uma evolução. Assim, os modelos são aproximações altamente subjetivas, por não incluírem todas as observações ou medidas associadas, mas são valiosos por obscurecerem detalhes acidentais e por permitirem o aparecimento de aspectos fundamentais da realidade. Neste procedimento de transposição e elaboração de um esquema representativo, deve-se salientar que não é a realidade em si que se encontra representada, mas sim uma visão subjetiva de como se percebe e se compreende a realidade.

This abstraction represents a complex reality in the simplest way that is adequate for the purpose of the modelling. The best model is always that which achieves the greatest realism (measured objectively as agreement between model outputs and real-world observations, or less objectively as the process insight gained from the model) with the least parameter complexity and the least model complexity” (MULLIGAN & WAINWRIGHT, 2004)

Os modelos espaço temporais reúnem alguns aspectos distintos, tais como: a escolha de conceitos adequados do espaço e do tempo; a escolha de um nível adequado de abstração, de forma a considerar informações relevantes ao objeto de estudo e desconsiderar aquelas que não são pertinentes; e a construção de representações computacionais apropriadas correspondentes a esses conceitos, ou seja, a linguagem utilizada para representação do modelo (De Lima, T. et al., 2009; Dias, et al., 2005).

Na modelagem de fenômenos geográficos é necessário responder perguntas clássicas como “porque”, “quando” e “onde” para que se possa descrever qualitativamente um fenômeno e prever sua evolução, integrando suas escalas temporais e espaciais. Nesse sentido, Steinitz (2012) apresenta seis modelos (Fig. 05) que descrevem o processo de planejamento global sobre a ótica do Geodesign:

The geodesign framework – by Carl Steinitz

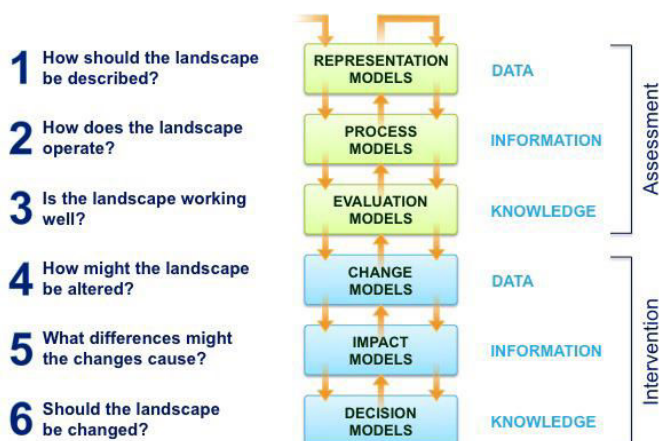


Figura 5: Framework for Geodesign - Fonte: STEINITZ (2012)

Segundo Steinitz (2012), os três primeiros modelos (modelos 1, 2 e 3) compreendem o processo de avaliação, olhando para as condições existentes dentro de um contexto geográfico. Os três modelos seguintes (modelos 4, 5 e 6) compreendem o processo de intervenção, olhando como o contexto pode ser mudado, as possíveis consequências dessas mudanças e se o projeto deve ser alterado.

Para Flaxman (2010), Geodesign é um projeto e um método de planejamento que casa firmemente à criação de uma proposta de projeto com simulações de cenários e impactos informados pelo contexto geográfico. Ou seja, o profissional, ou “Geodesigner”, trabalha com a capacidade propositiva de gerar cenários de planejamento, e avaliar suas consequências de acordo com um conjunto de métricas/regras. Sendo assim, a modelagem de mudanças na paisagem, modelo 4 no processo de Geodesign, abrange as seguintes etapas:

- **Modelo conceitual:** Refere-se ao levantamento das entidades e dos relacionamentos que se dão no fenômeno a ser estudado. É a compreensão de como se dá o comportamento espaço-temporal do evento a ser analisado.
- **Formulação matemática:** As hipóteses qualitativas devem ser expressas em linguagem matemática. Nesta etapa, deve-se usar das informações disponíveis para a construção do modelo e avaliar a correção dos enunciados e das equações que descrevem o comportamento dinâmico dos elementos e processos do sistema. Esta etapa requer que as formulações e os conceitos vagos sejam definidos pelo rigor do critério matemático; O resultado deste nível de abstração é a conceituação humana da realidade descrita na forma matemática. Normalmente só as

propriedades consideradas relevantes são incorporadas ao modelo.

- Verificação/Teste de integridade do modelo: Refere-se aplicar o modelo e verificar se todas as variáveis estão conectadas e avaliar seus valores, unidades e equações que as representam. Deve-se, portanto verificar se os algoritmos e os códigos computacionais estão corretos para as definidas relações matemáticas. Isto pode ser feito através do uso de técnicas numéricas, ou seja, resolver as questões pelo uso de procedimentos computadorizados.
- Calibração: Refere-se à etapa de avaliar/testar se os valores dos coeficientes das equações estão corretos, se as variáveis selecionadas respondem pelo modelo e se o modelo chega a um resultado aceitável.
- Validação: Verificar se os resultados obtidos são confiáveis e o quão próximo da realidade eles estão. Cabe ressaltar que o processo de calibração e validação se dá com dados diferentes. Uma possibilidade de aplicação é calibrar o modelo com os dados do T0 -> T1 e a validação se dar do T1 -> T2. Desta forma, comparam-se os dados simulados com o cenário real.
- Projeções Modeladas: Qualquer descrição do futuro ou dos caminhos que levarão à ele. Refere-se aos resultados obtidos no modelo após a simulação dos pressupostos adotados e das regras de transição aplicadas.
- Cenário: Após a definição dos objetivos, parte-se para a etapa que se configura com a formulação de hipóteses territoriais, ou seja, criar uma suposição de algo verossímil, possível de ser verificado, a partir da qual se extrai um resultado. Em outras palavras, é verificar a "chance" ou "possibilidade" de um determinado fenômeno acontecer, ou ser intensificado/minimizado diante de condições previamente estabelecidas e validadas.

Esta técnica tem sido usada como ferramenta de apoio a decisão em todo o mundo, tanto para modelagem de sistemas ambientais como, mais recentemente, para estudos urbanos.

2.1 MODELOS DE SIMULAÇÃO COMO FERRAMENTA DE APOIO À COMPREENSÃO DOS PADRÕES E PROCESSOS NA CONFIGURAÇÃO DA PAISAGEM

A paisagem pode ser compreendida como aquilo que vemos. É a junção do ambiente natural e do construído. Para Holzer (1997), a paisagem incorpora ao suporte físico os traços que o trabalho humano, que o homem como agente e não como mero espectador, imprime aos sítios

onde vive. Mais do que isso, ela denota o potencial que um determinado suporte físico, a partir de suas características naturais, pode ter para o homem que se propõe a explorá-lo com as técnicas de que dispõe.

Para Serpa (2010), a paisagem resulta sempre de um processo de acumulação, mas é, ao mesmo tempo, contínua no espaço e no tempo, é una sem ser totalizante, é compósita, pois resulta sempre de uma mistura, um mosaico de tempos e objetos datados. A paisagem pressupõe um conjunto de formas e funções em constante transformação, que são seus aspectos “visíveis”. Por outro lado, as formas e as funções indicam a estrutura espacial, em princípio “invisível”, e resulta sempre do casamento da paisagem com a sociedade.

Já para Santos (1997) a paisagem nada tem de fixo, de imóvel. Cada vez que a sociedade passa por um processo de mudança, os setores econômico, das relações sociais e político também mudam, em ritmos e intensidades variados. A mesma coisa acontece em relação ao espaço e à paisagem que se transforma para se adaptar às novas necessidades da sociedade.

A paisagem apresenta um padrão espacial que é influenciado por fatores naturais (geológicos, geomorfológicos, cobertura vegetal, tipo de solo, declividade, entre outros) assim como por fatores antrópicos (zoneamentos propostos nas legislações urbanísticas e ambientais, distribuição espacial de infraestruturas, serviços, postos de trabalhos, entre outros) e de ambos concomitantemente, resultando em um padrão espacial específico.

Entende-se por padrão o arranjo espacial dos elementos, ou seja, a forma como o conjunto de objetos ou formas espaciais criados pelo homem, ou não, se distribuem no espaço geográfico ao longo da história. É o mesmo que arranjo espacial ou configuração espacial. Desta forma, o padrão espacial também sofre influência dos processos naturais e antrópicos que atuam no espaço geográfico, que por sua vez interferem no padrão de ocupação espacial adotado pela sociedade, tornando este sistema cíclico, passível de se retroalimentar (*feedback*) e dinâmico. Compreender essa dinâmica espaço-temporal é necessário para o entendimento da evolução dos processos e padrões e, conseqüentemente, da configuração dessa paisagem futura.

Diante do exposto, o uso de tecnologias como os Modelos de Simulação (*Simulation Models*) nos auxilia no entendimento destes aspectos aqui apresentados. Segundo o Geographical Sciences Committee (2014), os Modelos de Simulação são, em geral, construídos para testar teorias e conceitos de alterações na paisagem associadas com as dinâmicas humanas e ambientais e para explorar as implicações dessas dinâmicas em projeções futuras baseadas nas

observações do mundo real.

The policy and practitioner communities are concerned with guiding land use decision making, for which LCMs provide value by enabling exploration of the possible outcomes of those decisions. These distinctions notwithstanding, LCMs inform and are used by many research and practitioner communities to address topics related to the processes of and outcomes from land change across a wide range of domains of relevance to environmental change and sustainability, including: Land-climate interactions; Water quantity and quality; Biotic diversity, ecosystem function, and trade-offs among ecosystem services; Food and fiber production; Energy and carbon (sequestration); and Urbanization, infrastructure, and the built environment (GEOGRAPHICAL SCIENCES COMMITTEE, 2014).

As dinâmicas no uso e cobertura do solo são complexas e envolvem diversos componentes e processos sociais, bioquímicos, biogeográficos, ecológicos e socioeconômicos, os quais podem ser integrados nos Modelos de Simulação, já que estes aspectos podem ser considerados como *inputs* nestes modelos. Assim como os *outputs* dos Modelos de Simulação podem ser usados como *inputs* na avaliação destes outros componentes.

Complexity is present in land system dynamics because of social and biophysical heterogeneity, spatial and social interactions, natural and human adaptation, and feedbacks among system components. This leads to variation in outcomes by geographical location, social group, or ecosystem type, and to nonlinear dynamics that can complicate attempts to validate and predict models. Virtually all LCMs produce outcomes that are spatially explicit, either in terms of land use and cover or specific biophysical (e.g., NPP, leaf area index, roughness) or socioeconomic (e.g., income levels and distributions, age) variables. Complexity typically enlarges the sensitivity of model outcomes to boundary conditions (GEOGRAPHICAL SCIENCES COMMITTEE, 2014).

Os Modelos de Simulação tem sido aperfeiçoados ao longo do tempo com os avanços tecnológicos (software e hardware), nas técnicas estatísticas, sobretudo a estatística espacial, e com os maiores investimentos na aquisição e manutenção dos dados geográficos.

Models have improved in their ability to treat spatial, temporal and decision-making complexity as described by Agarwal (2002) and render detailed outputs, from spatial scales of 1 m to 500 km. Model performance is linked to both the quality and resolution of the data employed and the degree of fidelity in representing the processes of land change. Machine learning, data mining, and statistical methods have advanced to improve our ability to identify patterns in the changes we observe. Economic modelers have taken advantage of spatially explicit data sets to build and improve models with varying levels of detail on economic decision making. Agent-based models have increased our capacity to address different types of agents (e.g., households, land managers) and their behaviors, especially when backed by empirical data about that behavior (MANSON & T. EVANS, 2007).

Como explica o Geographical Sciences Committee (2014), apesar dos avanços os Modelos de Simulações da paisagem (*Land Simulation Models*) enfrentam uma série de limitações que derivam tanto de restrições de dados quanto de limites de compreensão dos usuários em relação a processos subjacentes. As limitações de dados podem ser caracterizados de várias maneiras, incluindo aquelas devido ao sensor ou fonte (por exemplo, as resoluções espacial, espectral e temporal), as limitações em função da entrada dos dados brutos (por exemplo, a falta de uma única ontologia de uso da terra ou cobertura do solo que possa ser usada para a classificação em todas as aplicações), e as limitações devido à falta de conhecimento em como proceder ou ainda, acesso restrito a uma variedade de dados primários públicos ou privados sobre os sistemas terrestres.

A representação de processos nos Modelos de Simulação são ainda mais difíceis de serem modelados devido a sua complexidade e característica não-estacionária. Por isso uma maior indicação para projeções temporais de curto prazo, destacando-se a possibilidade de limites reais para o nível de previsão que se pode esperar dos Modelos de Simulação (BATTY e TORRENS, 2005).

Conseqüentemente, no processo de modelagem quanto mais para o futuro os resultados forem projetados, maior é a incerteza dessas saídas. Para diminuir a incerteza das saídas nas projeções é preciso investimentos nos algoritmos dos modelos para que estes consigam representar de forma mais realista, a longo prazo, os mecanismos de feedback dos sistemas terrestres, assim como o fator multi-escala, geralmente não representados.

Segundo Geographical Sciences Committee (2014), o mais importante é que os modelos estão apenas começando a explicar interações espaciais e sociais entre as diferentes unidades de terra, os usuários da terra e os processos ambientais ligados a eles, especialmente como são afetados pela forma e padrão de unidades de terra e as estruturas de rede de interações sociais. Cabe ao modelador, portanto, identificar o melhor modelo para representar seu objeto de estudo e estar ciente de suas limitações.

2.2 TIPOS DE DADOS USADOS NOS MODELOS DE SIMULAÇÃO

Os Modelos de Simulação da paisagem apresentam como dados básicos essenciais o mapeamento do uso ou cobertura do solo e as variáveis explicativas do objeto de estudo.

O mapeamento da Cobertura do Solo compreende a caracterização do estado físico, químico e

biológico da superfície terrestre. São exemplos de classes de cobertura do solo: vegetação densa, vegetação rasteira, água, área construída, solo exposto. O Uso do Solo, por sua vez, refere-se aos propósitos humanos associados ao território, a exemplo da pecuária, recreação, conservação, área residencial, comercial, mineração, etc. No caso urbano, a cobertura do solo pode ser solo exposto ou área densamente ocupada, ao passo que o uso pode ser residencial ou comercial. As variáveis explicativas, por sua vez, são aquelas que serão usadas para auxiliar na elaboração das regras de transição do uso/cobertura do solo de acordo com o modelo escolhido.

Os dados de cobertura são geralmente elaborados através de dados de sensoriamento remoto. Estes têm melhorado nos últimos anos com os avanços na geoestatística (KALIRAJ, et al., 2012), inteligência artificial (GHOSH, et al., 2008), e análises temporais (VERBESSELT, et al., 2010), permitindo uma expansão e um melhoramento no tipo de informação que se pode extrair dos dados originados do sensoriamento remoto. Além disso, algoritmos de classificação orientados a objetos, uma maior variedade de sensores orbitais, e conseqüentemente maior oferta de dados com resoluções espaciais, temporais, espectrais e radiométricas diferentes, tem favorecido para os avanços em pesquisas com os Modelos de Simulação. Para estudos em escala regional conta-se com o acervo temporal de dados Landsat que são atualmente distribuídas gratuitamente. Para estudos em escala urbana é necessário imagens de média-alta (5m) a alta resolução espacial (menor ou igual a 1m) e infelizmente estes dados ainda não são distribuídos gratuitamente.

Os dados de uso do solo são elaborados baseados em dados cadastrais disponíveis nas prefeituras, ou por levantamento em campo. São informações de mais difícil acesso, entretanto, mais detalhadas que a de cobertura do solo. São dados mais usualmente aplicados em estudos de modelagem urbana.

Além dos dados de cobertura e/ou uso do solo, é possível, dependendo da complexidade dos Modelos de Simulação, entrar com variáveis auxiliares na composição das regras de transição. São as chamadas variáveis explicativas, adicionais, drivers ou independentes, que podem ser estimuladoras ou restritivas ao processo de mudança. São exemplos de variáveis que podem ser estimuladoras: algumas tipologias do zoneamento urbanístico, rodovias, concentração de comércio de serviços, declividade do terreno, etc. Já as variáveis adicionais restritivas podem ser exemplificadas como algumas tipologias do zoneamento urbanístico, como as grandes estruturas urbanas que são atritos ao crescimento da malha, tais como aeroportos,

universidades, unidades de conservação e proteção ambiental, corpos hídricos, etc. É possível ainda entrar com variáveis dinâmicas adicionais, como por exemplo, projetos aprovados e ainda não implementados. Dependendo da plataforma a ser utilizada, pode-se informar a data que as variáveis dinâmicas adicionais devem começar a ser consideradas no modelo de mudança.

Uma importante propriedade de todos os modelos é que eles contêm algum nível irredutível de incerteza que pode ser inerente à estrutura de modelo (isto é, as equações básicas ou algoritmos), os valores dos parâmetros, os dados de entrada, ou de todos estes. A incerteza é endêmica em nossa compreensão do uso da terra, tomada de decisão e do estado físico e função dos sistemas terrestres. Isto porque *“the future state of land systems will be determined by a combination of individual and societal constraints and opportunities about which decisions have yet to be made”* (GEOGRAPHICAL SCIENCES COMMITTEE, 2014).

Estes dados podem ser apresentados inicialmente nos formatos vetoriais e matriciais, mas para a utilização destes nos Modelos de Simulações todos devem seguir as seguintes recomendações, e assim minimizar as incertezas dos dados:

- Estarem todos configurados no mesmo sistema de projeção cartográfica;
- Estarem todos no mesmo formato (matricial ou vetorial);
- Caso o formato dos dados escolhidos for o matricial, estes devem apresentar o mesmo retângulo envolvente (coordenadas do canto superior e inferior devem ser iguais, inclusive nas casas decimais, além de mesmo número de linhas e colunas);
- O tamanho do pixel deve ser o mesmo em todas as matrizes, para favorecer as análises;
- Os dados devem estar normalizados em uma mesma escala numérica, onde valores menores indiquem menor potencial de mudança e valores maiores indiquem maior potencial de mudança;

Além disso, ao final da projeção futura o resultado deve ser testado estatisticamente e apresentar um nível de confiabilidade. A avaliação dos resultados vai depender da metodologia que foi empregada na construção do modelo de mudança.

2.3 MODELOS DE SIMULAÇÃO: REGRAS DE TRANSIÇÃO E METODOLOGIAS

Um modelo é constituído de pelo menos três elementos: variáveis, relacionamentos e processos (PEDROSA & CÂMARA, 2004). Dependendo do objetivo do trabalho, a ênfase pode ser dada a um destes elementos no modelo.

Os Modelos de Simulação da Paisagem podem ser classificados como empíricos ou de sistemas. Segundo Pedrosa & Câmara (op. cit.), os modelos empíricos, em sua dimensão procedural, possuem três componentes chaves: uma configuração inicial, uma função de mudança e uma configuração de saída:

A configuração inicial de um modelo dinâmico pode ser obtida através de dados históricos do fenômeno em estudo, chamados de séries temporais. Neste caso, equações diferenciais (totais ou parciais) que incluem pelo menos um termo derivado no tempo podem ser utilizadas para representar o modelo e o processo é classificado como determinístico. Quando variáveis aleatórias são utilizadas para explicar um sistema o processo é classificado como estocástico-probabilístico (PEDROSA & CÂMARA 2004).

Modelos empíricos são caracterizados pela simplicidade dos modelos matemáticos empregados e pelo número reduzido de variáveis envolvidas. Como exemplo, podem-se citar as Cadeias de *Markov*, modelos logísticos e os modelos de regressão. Já os “Modelos de Sistemas”, segundo Pedrosa & Câmara (2004), procuram descrever o sistema como um todo, isto é, tentam representar as interações entre os seus componentes. Uma característica chave destes modelos é a eficiência com que abordam a dimensão espacial, implantando conceitos tais como as relações de vizinhança e suportando o uso combinado de múltiplas escalas. Como exemplos de modelos de sistemas podem-se citar os modelos de simulação de ecossistemas e os modelos de simulação dinâmica espacial.

Uma condição comum aos modelos de projeção do uso/cobertura do solo é atender ao requisito de “*Pure pixels*”, o que significa que o modelo usa *pixels* que possuem adesão completa a exatamente uma categoria, ao contrário de *pixels* misturados que têm adesão parcial para mais de uma categoria, como por exemplo os *pixels* de imagens hiperespectrais. Este *pixel* apresenta apenas a resposta espectral de um alvo ou a imagem foi reclassificada dando um valor único para cada *pixel*, como por exemplo, uma tipologia de uso/ocupação (PONTIUS JR. et al, 2008; VALENCIA et al., 2005; CHANG, 1999).

A seguir são apresentados alguns exemplos das metodologias usadas na projeção e simulação de mudanças no uso/cobertura do solo. As metodologias de projeção são apresentadas com a

metodologia de identificação e definição das regras de transição mais usualmente usadas. Cabe ressaltar que estes métodos podem ser usados separadamente ou mais de um ao mesmo tempo, dependendo da complexidade do algoritmo do modelo empregados e pelo número reduzido de variáveis envolvidas.

2.3.1 Métodos de auto - aprendizagem e metodologias de projeção baseada em “*Exogenous quantity*” e “*Machine Learning*”

O processo de modelagem e projeção de cenários do uso/cobertura do solo em geral une uma técnica que permita identificar as regras de transição a outra técnica para fazer a projeção das mudanças.

Atualmente temos uma infinidade de diferentes metodologias em ambas etapas do processo de modelagem que nos permitem fazer inúmeras combinações entre elas. Neste momento apresentaremos as técnicas de projeção baseada em *Exogenous Quantity* e o métodos de aprendizagem ou *Machine Learning*.

Entende-se por “*Exogenous Quantity*” que o modelador especificará a quantidade que cada categoria terá no mapa de predição e que esta predição será independente da localização inicial das categorias. O valor a ser informado pode ser calculado usando diferentes técnicas como regressão linear, regressão logística ou mesmo a Cadeia de *Markov*. (GOMES, 2013; BREDEWEG, et al, 2007; PONTIUS JR. et al, 2008).

O método de *Exogenous quantity* sozinho não apresenta a possibilidade de usar variáveis “*drivers*” ou variáveis “explicativas da mudança”, por isso é mais interessante a aplicação desta técnica com outra que possa identificar as regras de transição. Além disso, o método de *Exogenous Quantity* desconsidera a localização inicial da classe a ser projetada, o que faz o uso deste método sozinho ser desaconselhável, já que é um modelo espacialmente implícito.

A metodologia baseada em “*Machine Learning*” envolve abordagens para representar relações entre entradas (ou seja, variáveis de condução) e saídas (mapa resultado). Diferentes dados (variáveis explicativas) são usados para gerar mapas de potenciais de transição que dão uma medida empírica (data drive) baseados na possibilidade de transições de terras. O algoritmo do modelo é executado por um período indeterminado de tempo até que este aprenda os padrões dos dados de calibração, e em seguida, utilize estes padrões aprendidos para fazer uma previsão. Estes padrões de aprendizado podem estar baseados em diferentes

metodologias como regressão logística, modelagem linear, redes neurais, pesos de evidência, estatística Bayseana. (PONTIUS JR. et al, 2008; GEOGRAPHICAL SCIENCES COMMITTEE, 2014). Cabe apresentar de forma mais aprofundada os métodos baseados em Regressão Linear e mais adiante, Redes Neurais Artificiais.

2.3.1.1 Métodos estatísticos de estimação - Regressão Linear simples e Múltipla, Regressão Logística Simples, Múltipla e Multinomial

Os métodos estatísticos de estimação de parâmetros são usados para estimar os valores do sistema a partir de dados do universo ou da amostra. O método de “*Regressão Linear*” usa de técnicas estatísticas para fazer previsões de uma variável considerando o comportamento de outra (s). Tem por objetivo estabelecer uma equação que possa ser usada para prever valores de Y para valores dados por uma ou por diversas variáveis independentes (PONTIUS JR. et al, 2008; PETERNELLI, 200-). O método de regressão estatística pode ser denominado como linear, logístico, logístico multinomial, entre outros.

O método de regressão linear simples buscará estabelecer uma equação linear que possa ser usada para prever valores de Y baseado em 01 (uma) variável independente. Esta pode ser qualquer variável que o pesquisador busque entender o relacionamento da variável Y com a variável independente, por exemplo: entender a correlação entre o urbano e a densidade de vias ou de comércio, ou deste com a proximidade da vegetação rasteira, entre outros. A ideia aqui seria tentar explicar o padrão de mudança do uso do solo baseado na variável escolhida. O modelo estatístico para esta situação, segundo Pertinelli (2007) seria:

$$Y_i = B_0 + B_1X_i + e_i$$

Equação 1

Em que:

- Y_i = valor observado para a variável dependente Y no i-ésimo nível da variável independente X.
- B_0 = constante de regressão. Representa o intercepto da reta com o eixo Y.
- B_1 = coeficiente de regressão. Representa a variação de Y em função da variação de uma unidade da variável X.
- X_i = i-ésimo nível da variável independente X ($i = 1, 2, \dots, n$)
- e_i = é o erro que está associado à distância entre o valor observado Y_i e o correspondente ponto na curva, do modelo proposto, para o mesmo nível i de X. Este é

o resíduo no contexto de Sistemas Complexos em modelos temporais.

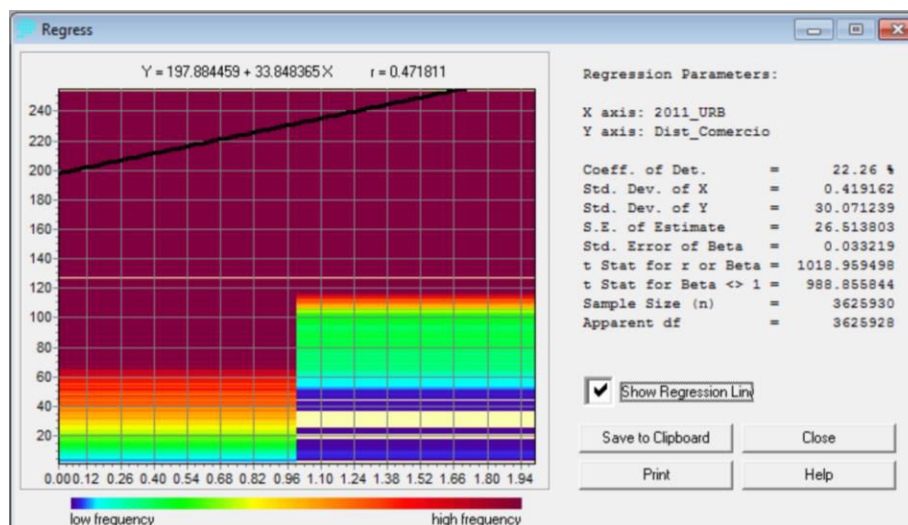


Figura 6: Parâmetros da Regressão Linear

Por exemplo, ao tentarmos estabelecermos uma relação entre a variável dependente: Cobertura do solo (com tipologias de uso/cobertura: urbano e não urbano, Eixo X) e a variável independente “Distância de atividades comerciais” (Eixo Y), teremos como resposta uma reta de inclinação positiva, o que significa que há uma maior frequência de ocorrência da variável independente quando ocorre a variável dependente, ou seja, a concentração do comércio é maior em áreas urbanas (Fig. 6).

O coeficiente de determinação ou r^2 para o caso de regressão linear simples, fornece uma informação auxiliar ao resultado da análise de variância da regressão como uma maneira de se verificar se o modelo proposto é adequado ou não para descrever o fenômeno.

O valor de r^2 varia no intervalo de 0 a 1. Valores próximos de 1 indicam que o modelo proposto é adequado para descrever o fenômeno. O r^2 indica a proporção (ou porcentagem) da variação de Y que é “explicada” pela regressão, ou quanto da variação na variável dependente Y está sendo “explicada” pela (s) variável (s) independente (s) X. No nosso exemplo, a variável Distância de centros Comerciais responde por 22.26% do uso do solo (urbano e não urbano). Quando fazemos esta análise com um mapa de uso do solo com quatro tipologias de uso (agua, urbano, vegetação densa e vegetação rasteira), o percentual de resposta da variável independente cai para 8%, o que é totalmente justificado, já que as dinâmicas de transformação nestes outros usos não são explicados por esta variável. Aconselha o uso desta técnica para um estudo exploratório das variáveis independentes que serão usadas no Modelo de Simulação da paisagem (FIGUEIRA, 2006; EASTMAN, 2012b; PETERNELLI, 200-).

Como demonstrado, o modelo de regressão simples apresenta algumas limitações, já que no caso de estudos urbanos é necessário mais de uma variável independente para explicar o comportamento da variável dependente. Na regressão múltipla, uma relação linear é assumida entre a variável dependente e as variáveis independentes. Sendo assim, podemos apresentar mais de uma camada de informação para tentar responder pelo processo de previsão de mudanças no uso do solo, ou seja, não precisamos limitar a pesquisa a uma única variável explicativa/independente. A finalidade das variáveis independentes adicionais é melhorar a capacidade de predição se comparada com a regressão linear simples (FIGUEIRA, 2006; PETERNELLI, 200-; EASTMAN, 2012b). No caso de três variáveis independentes, por exemplo, a equação de regressão linear múltipla pode ser escrita como:

$$Y = a + b1 * x1 + b2 * x2 + b3 * x3$$

Equação 2

onde Y é a variável dependente (uso do solo, por exemplo), $x1$, $x2$ e $x3$ são as variáveis independentes, a é a intersecção, e $b1$, $b2$ e $b3$ são os coeficientes das variáveis independentes $x1$, $x2$ e $x3$, respectivamente. A intersecção representa o valor de Y quando os valores das variáveis independentes são zero, e o coeficiente indica mudança de unidade de Y com um aumento de uma unidade na variável independente correspondente (EASTMAN, J. R. 2012B; PETERNELLI, 2007).

Segundo Triola (2005), algumas suposições subjacentes ao uso de regressão devem ser consideradas, tais como:

- As amostras devem apresentar observações independentes;
- Existir relação linear entre x e y ;
- Quaisquer *outliers* que correspondam a erros do banco de dados devem ser removidos.
- Homoscedasticidade dos resíduos (variância constante dos erros para observações diferentes): *Teste de Breusch-Pagan e Goldfeld-Quandt*
- Resíduos devem apresentar distribuição normal e sem padrões

Como resultados, a análise multivariada apresentará uma imagem da projeção das mudanças uma imagem dos resíduos (Fig. 07) e os parametros estatísticos para serem analisados (Fig. 08).

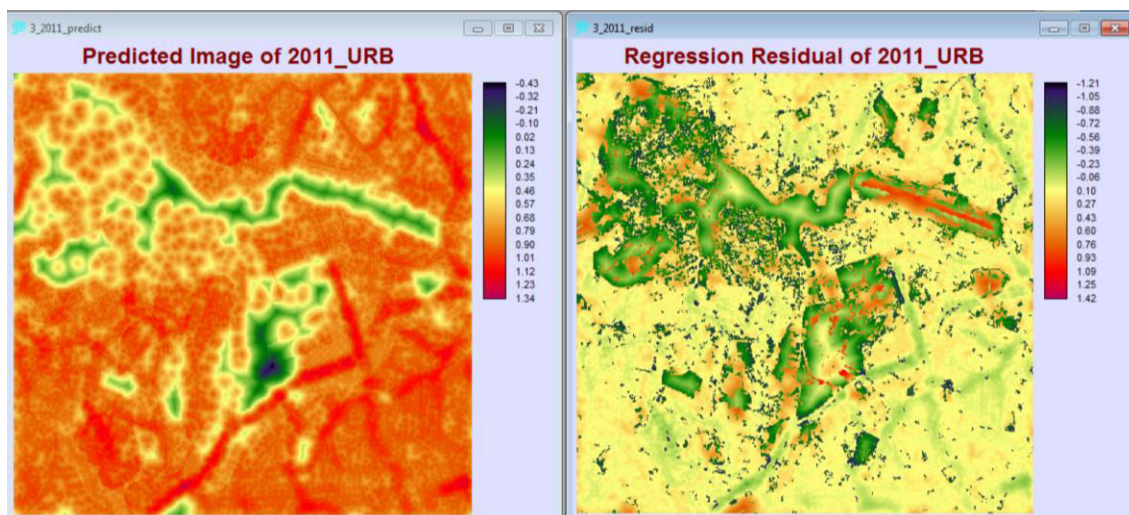


Figura 7: Projeção suavizada e mapa de resíduos da Regressão Múltipla

O mapa dos valores previstos é um mapa de potencial de transformação suavizado, no sentido de que há variabilidade aleatória, já que outros fatores não foram incluídos no modelo. O mapa residual pode nos dar a indicação da sistemática super ou subvalorizada na previsão em determinadas regiões, o que poderia ser uma evidência de correlação espacial, a ser avaliada com mais rigor por meio de um teste de hipóteses (ANSELIN, 2005).

Valores residuais elevados positivos ou negativos (Fig 07) indicam que o modelo não está conseguindo fazer a previsão naquele lugar e que portanto, as variáveis independentes não respondem pela dinâmica de transformação nesta localidade. Valores próximos a zero indicam que estas feições mantiveram se as mesmas na paisagem, ocorrendo pouca ou nenhuma mudança, o que pode sugerir uma maior estabilidade destas feições ou que a área foi sub-analisada (ANSELIN, 2005; EASTMAN, 2012b).

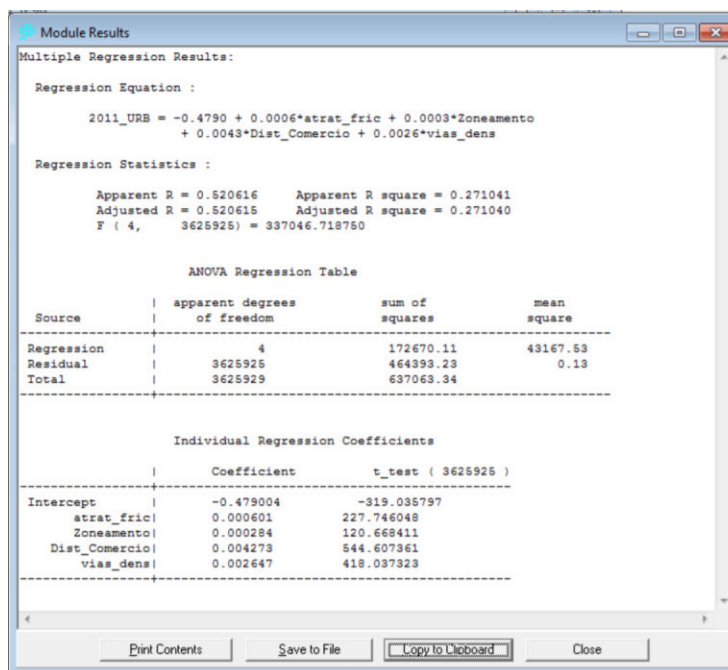


Figura 8: Output das Estatísticas de Regressão múltipla

No que se refere á interpretação estatística dos resultados, segundo Figueira (2006); Peternelli (200-) e Eastman (2012b), temos que:

- R = indica o quanto que a variável dependente está correlacionada com as variáveis independentes; Este índice varia de 0 a 1, onde quanto maior o valor, maior a correlação;
- R^2 ou *R square* = indica o quanto que o comportamento da variável dependente pode ser explicado pelas variáveis independentes. Este valor é expresso em percentual.
- R e R^2 ajustados são os valores de R e R^2 corrigidos pelo número das variáveis independentes;
- *F value* indica o quanto que estas variáveis independentes juntas contribuem para a explicação da variável dependente; Para saber se o valor é válido, ele deve ser maior do que o valor apresentado na Tabela F (*Table V. Critical values for F-test for Alpha = 0.01*). Caso o valor apresentado seja menor que o valor da Tabela, é preciso repensar as variáveis independentes.
- Tabela ANOVA: é onde serão apresentados os dados para que seja feita a análise da variância de forma alternativa ao já apresentado.
- Coeficiente de Regressão individual (efeito do Fator): expressa o coeficiente individual de cada variável independente na influência do comportamento da variável dependente; A significância de seus resultados é apresentado em estatística de T.

Já a Regressão logística é binomial, ou seja, a variável dependente de entrada deve ser de natureza binária e pode ter apenas dois valores possíveis (0 e 1). Tal análise de regressão é geralmente empregue em estimar um modelo que descreve a relação entre uma ou mais variáveis contínuas independente (s) para a variável dependente binária, geralmente de caráter nominal ou qualitativo (FIGUEIRA, 2006; PETERNELLI, 200-; EASTMAN, 2012b).

Se o modelo usa uma variável independente para explicar o processo de mudança chamamos o modelo de Regressão Logística Simples, se usa mais de uma variável independente, Regressão Logística Múltipla. O pressuposto básico de linearidade é que a variável dependente deve assumir o valor de 0 (resposta negativa) ou 1 (resposta positiva). Sendo assim, podemos afirmar que esta segue a curva logística e seu valor pode ser estimado com a seguinte fórmula:

$$P (y=1|X) = \frac{\exp (\Sigma BX)}{1 + \exp (\Sigma BX)}$$

Equação 3

Onde:

P é a probabilidade da variável dependente ser 1;

X é a variável independente,

$X = (x_0, x_1, x_2, \dots, x_k)$, $X_0 = 1$

B é o parâmetro de estimativa;

$B = (b_0, b_1, b_2, \dots, b_k)$,

São alguns princípios do modelo de regressão logística, segundo EASTMAN, (2012b):

The dependent random variable, Y, is assumed to be binary, taking on only two values (0 and 1); the outcomes on Y are assumed to be mutually exclusive and exhaustive; Y is assumed to depend on K observable variables Xk and the relationship is non-linear and follows the logistic curve; the data are generated from a random sample of size N, with a sample point denoted by i, i = 1, ..., N; no restriction on the independent variables except that they can not be linearly related (implies that N>K); the error term of each observation is assumed to be independent of the error terms of all other observations (EASTMAM, 2012b)

Como resultado da projeção baseada em Regressão Logística, na plataforma *IDRISI*, apresentamos o mapa projetado do potencial de transformação e as estatísticas (Fig. 09):




Figura 9: Imagem projetada da Pampulha á partir da cobertura do solo de 2011 e os resultados estatísticos da Regressão logística múltipla

No que se refere á interpretação estatística dos resultados, segundo Eastman (2012b), temos que:

- Pseudo R2 = indica o quanto que o comportamento da variável dependente pode ser explicado pelas variáveis independentes; Este valor é expresso em percentual. Quanto maior o valor, melhor a projeção.
- Coeficiente de Regressão individual: expressa o coeficiente individual de cada variável independente na influência do comportamento da variável dependente; O sinal positivo ou negativo expressa o tipo de relacionamento que esta variável tem com a variável dependente, sendo positivo se sua frequência de ocorrência aumenta quando está na categoria analisada e negativo se sua frequência diminui. Esta afirmação só pode ser feita se todas as variáveis estão na mesma resolução espacial ou escala.
- ROC (Característica de Operação Relativa) é um método para comparar o mapa booleano "real" versus o mapa de aptidão. Assim, ROC é incluído aqui como uma excelente estatística para medir a qualidade do ajuste da regressão logística. O valor ROC varia de 0 a 1, onde 1 indica um ajuste perfeito e 0,5 indica um ajuste aleatório. Um valor ROC entre 0,5 e 1 indica alguma associação entre as variáveis X e Y. Quanto maior o ROC, melhor o ajuste.

Já a Regressão Logística Multinomial caracteriza-se por apresentar uma variável dependente, de entrada multicategórica, e por trabalhar com variáveis independentes contínuas. Por ser um

tipo de Regressão Logística, esta técnica permite que o usuário informe qual tipologia de classe deve ser usada como referência para a análise com as variáveis independentes (PETERNELLI, 200-; EASTMAN, 2012b)

A Regressão Logística Multinomial compartilha a mesma lógica básica da Regressão Logística Binomial, onde ambas assumem a variável dependente após a distribuição de probabilidade logística e o método de Máxima Verossimilhança para a estimativa da probabilidade das mudanças (EASTMAN, 2012b).

Para uma variável dependente com as categorias de resposta K, a Regressão Logística Multinomial requer uma equação K-1 da função *logit* (função de ligação entre a probabilidade e a projeção), para cada uma das categorias, em relação à categoria de referência, descrevendo assim a relação entre a variável dependente e as variáveis independentes (PETERNELLI, 200-; EASTMAN, 2012b, DOS REIS FREITAS, et al., 2013). Dada a categoria 0 (zero) como categoria de referência, matematicamente, é representado pelas seguintes funções, de acordo com Eastman (2012b):

$$g_1(x) = \ln \left[\frac{P(Y = 1 | X)}{P(Y = 0 | X)} \right] = \beta_{10} + \beta_{11}x_1 + \beta_{12}x_2 + \dots + \beta_{1q}x_q = X'\beta$$

$$g_2(x) = \ln \left[\frac{P(Y = 2 | X)}{P(Y = 0 | X)} \right] = \beta_{20} + \beta_{21}x_1 + \beta_{22}x_2 + \dots + \beta_{2q}x_q = X'\beta$$

and

.

.

$$g_k(x) = \ln \left[\frac{P(Y = k | X)}{P(Y = 0 | X)} \right] = \beta_{k0} + \beta_{k1}x_1 + \beta_{k2}x_2 + \dots + \beta_{kq}x_q = X'\beta$$

Equação 4

Onde:

$g_k(x)$ é a função logit da categoria K em relação á categoria de referência;

X é o vetor (covariante) da variável independente, $X = (x_1, x_2, \dots, x_n)'$

β_k é o coeficiente do vetor estimado por categoria K, $\beta_k = (\beta_{x0}, \beta_{x1}, \dots, \beta_{xn})^t$

Em seguida, cada valor projetado pode ser definido pela fórmula:

$$P(Y = 0 | X) = \frac{1}{1 + e^{\beta_1(X)} + e^{\beta_2(X)} + \dots + e^{\beta_k(X)}}$$

$$P(Y = 1 | X) = \frac{e^{\beta_1(X)}}{1 + e^{\beta_1(X)} + e^{\beta_2(X)} + \dots + e^{\beta_k(X)}}$$

and

$$P(Y = k | X) = \frac{e^{\beta_k(X)}}{1 + e^{\beta_1(X)} + e^{\beta_2(X)} + \dots + e^{\beta_k(X)}}$$

Equação 5

Outro fator que diferencia a Regressão Logística Simples ou Múltipla da Multinomial é o mapa projetado resultante. Este não será um mapa suavizado da probabilidade de mudanças, mas um mapa explicitando as alterações no uso/cobertura do solo por ítem de legenda. Como resultado, a Regressão Logística Multinomial, na plataforma IDRISI, apresenta o mapa projetado, o qual considerou uma classe de referência para projetar as mudanças na cobertura do solo; os resultados estatísticos, cujo componentes para interpretação e análise foi descrito nas regressões anteriores (Fig. 10); as imagens de probabilidade de mudança de acordo com os ítems de legenda (Fig. 11 e 12), normalizados na escala de 0 (zero) a 1 (um), onde valores maiores indicam maior probabilidade de mudança:

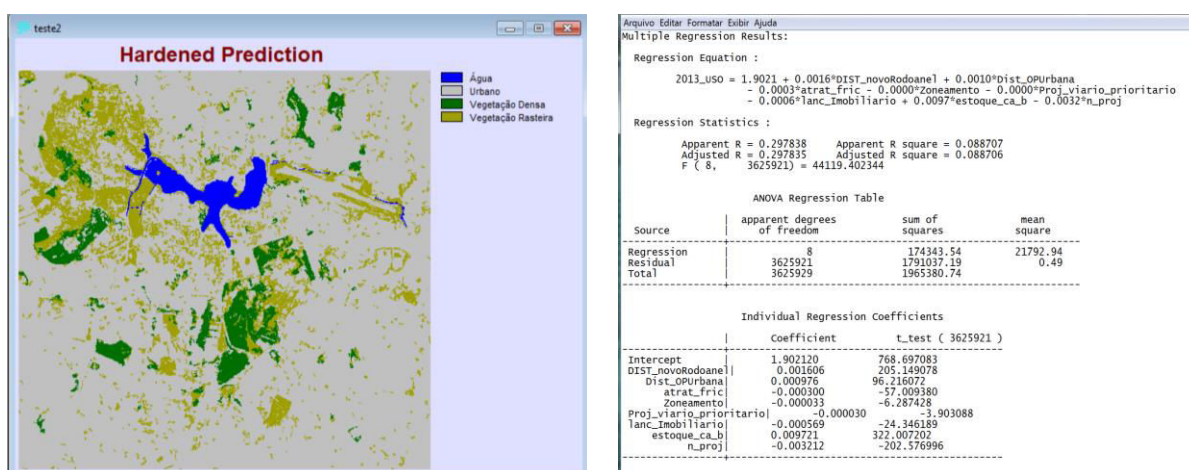


Figura 10: Projeção do uso do solo por Regressão Logística Multinomial e Resultados estatísticos




Figura 11: Imagens de probabilidade de mudança considerando as tipologias Água e Urbano

Nesta análise, informamos como categoria de referência a tipologia Urbano – classe 2. Isto indica que buscamos, através das variáveis independentes responder pelo comportamento desta categoria através do método de Máxima verossimilhança, o qual busca nas variáveis independentes pelos padrões comportamentais observados nos dados de uso/cobertura do solo.




Figura 12: Imagens de probabilidade de mudança considerando as tipologias Vegetação Densa e Rasteira

Sendo assim, podemos dizer que se estamos interessados na relação de apenas uma variável de entrada com a variável resposta temos o caso de Regressão Linear Simples. Se queremos relacionar a variável dependente com mais de uma variável independente então usaremos a Regressão Linear Múltipla. Caso a variável dependente seja uma variável categórica, ou seja, a variável apresente como possíveis realizações uma qualidade (ou atributo, por exemplo, de

tipologias de uso do solo) e não mais uma mensuração, utilizamos o Modelo de Regressão Logística.

Tabela 1: Quadro síntese das metodologias de Regressão quanto o tipo de variáveis e suas tipologias

REGRESSÃO	VARIÁVEL DEPENDENTE	TIPOLOGIA DE COBERTURA DO SOLO	VARIÁVEL INDEPENDENTE
Linear Simples	Contínua	Potencial de transformação	Uma
Linear Múltipla Simples	Contínua	Potencial de transformação	Duas ou mais
Logística Simples	Categórica	02 (duas) categorias qualitativas	Uma
Logística Múltipla	Categórica	02 (duas) categorias qualitativas	Duas ou mais
Logística Multinomial	Categórica	Mais de 02 (duas) categorias qualitativas, informar qual será a categoria de referência	Duas ou mais

Como exemplos de plataformas GIS que oferecem modelagem de cenários baseado em Regressão Linear podemos citar: SLEUTH, Conversion of Land Use and its Effects (CLUES); GEOMOD, REGRESS, MULTIREG, LOGISTICREG, MULTIREGREG (todos módulos da plataforma IDRISI); GEODA, ARCGIS, entre outros.

Regressão Linear tem sido usada em estudos que abordam mudanças na cobertura vegetal de florestas (RASHMI e LELE, 2010; DUSHKU e BROWN, 2003), para fazer a análise comparativa entre planos diretores e Plano de qualidade ambiental (TANG, 2008); para modelar a dinâmica do setor imobiliário (CRESPO e GRÊT-REGAMEY, 2013); modelar mudanças no uso do solo com variáveis independentes predominantemente socioeconômicas (OREKAN et al., 2008); modelar a expansão da mancha urbana (PONTIUS e CHEN, 2006; DE BENITO, et al., 2007; VELDKAMP e FRESCO, 1996; LIN, et al., 2011).

2.3.1.2 Métodos estatísticos de estimação - Redes Neurais

Redes Neurais Artificiais (RNA) é um método de aprendizagem (Learning Machine) e processamento automático inspirado no modelo biológico do cérebro, o qual tenta reproduzir seu comportamento no processo de aprendizagem. Estes relacionamentos se darão de forma ponderada por um algoritmo que se ajusta de forma iterativa. De uma forma geral, pode-se afirmar que as Redes Neurais Artificiais buscam identificar e reprojeter as conexões

existentes entre as camadas de informação a serem avaliadas e que este aprendizado por rede é usado para definir as regras de transição para então se projetar o cenário futuro. (ATKINSON e TATNALL, 1997; CHAN et al., 2001; CIVCO, 1993; HSIEH, 2009; KARUL e SOYUPAK, 2006; GENARO et al., 2010; GEOGRAPHICAL SCIENCES COMMITTEE, 2014).

Segundo Braga et al., (2000), a maioria dos modelos de redes neurais possui alguma regra de treinamento, onde os pesos de suas conexões são ajustados de acordo com os padrões apresentados. Em outras palavras, elas aprendem através de exemplos. Desta forma, arquiteturas neurais são tipicamente organizadas em camadas (Fig. 13), com unidades que podem estar conectadas às unidades da camada posterior.




Figura 13: Redes Neurais – Organização em Camadas. Adaptado de BRAGA et al.,(2000)

De acordo com Braga et al (2000), as camadas são classificadas em três grupos:

- Camada de Entrada: onde os padrões são apresentados á rede;
- Camadas Intermediárias ou Escondidas: onde é feita a maior parte do processamento, através das conexões ponderadas; podem ser consideradas como extratoras de características;
- Camada de Saída: onde o resultado final é concluído e apresentado.

Fazendo um paralelo com o método de regressão linear, a camada de entrada seria a variável dependente, as camadas intermediárias as variáveis independentes e a camada de saída o mapa projetado. Entretanto, no caso de métodos baseados em Redes Neurais seria necessário

a entrada de no mínimo duas variáveis de entrada/dependentes representando o fenômeno em tempos distintos, onde por amostra, as redes neurais buscariam identificar, nas camadas intermediárias/independentes, os fatores que explicam a dinâmica de comportamento das variáveis de entrada/dependentes. Posteriormente, aplica-se essas regras aprendidas com os próprios dados na projeção do dado a ser analisado.

Para Eastman (2012a), uma das principais vantagens da rede neural artificial é *“that it is distribution-free, i.e., no underlying model is assumed for the multivariate distribution of the class-specific data in feature space”*.

As redes neurais são não-lineares e podem ser concebidas como uma função matemática complexa que converte dados de entrada para uma saída desejada. O processo multicamada que usa um algoritmo de aprendizagem de propagação oculta é um dos modelos de rede neural mais amplamente utilizados. A rede multicamadas típica contém uma camada de entrada, uma camada de saída e uma ou mais camadas escondidas (embora a camada escondida seja geralmente adequado para a maioria dos problemas). Os nós da camada ocultos têm pesos desiguais e estes são fundamentais para o funcionamento do algoritmo de redes. Sem eles, este não teria capacidade de aprender e fazer uso dos efeitos de interação (ATKINSON e TATNALL, 1997; CHAN et al., 2001; CIVCO, 1993; HSIEH, 2009; KARUL e SOYUPAK, 2006). Matematicamente podem ser definidas como:

$$net_j = \sum_{i=1}^m w_{ij} o_i$$

Equação 6

Onde:

w_{ij} representa o peso das conexões i e j , e o_i é a conexão resultante que levará a projeção de i . A projeção de saída a partir de j é computada como:

$$O_j = f(net_j)$$

Equação 7

E o erro é dado por:

$$\Delta w_{ji(t+1)} = \eta \delta_j o_i + \alpha \Delta w_{ji(t)} \quad \text{Equação 8}$$

where, η is the learning rate, α is the momentum factor, and δ is the computed error.

Segundo Brown et al. (2000), as redes neurais possuem algumas propriedades que as tornam adequadas ao reconhecimento de padrões e à classificação de dados espaciais, entre as quais: (i) a habilidade em extrair padrões ocultos em conjuntos de dados que podem ser imperceptíveis aos olhos humanos e às técnicas estatísticas tradicionais; (ii) a capacidade de analisar dados sem nenhum conhecimento prévio do objeto de estudo; (iii) a possibilidade de trabalhar com dados ruidosos, limitados, interdependentes ou não-lineares; (iv) a possibilidade de adição contínua de novos dados; (v) a facilidade para a análise de grandes conjuntos de dados.

Os estudos baseados em redes neurais têm sido amplamente difundidos junto à comunidade acadêmica, com aplicações em estudos da configuração e dinâmica da paisagem em Parques Nacionais (DE LIMA, L et al., 2013); dinâmica e propagação de poluição sonora em ambientes urbanos (GENARO et al., 2010); no reconhecimento de padrões de distribuição espacial de recursos naturais (BROWN et al., 2000; COSTA e SOUZA FILHO, 2009; NÓBREGA e DE SOUZA FILHO, 2003), na elaboração do Zoneamento Ecológico-Econômico (MEDEIROS, 1999); em estudos na definição de áreas metropolitanas e/ou demográficas (GUILLAIN e LE GALLO, 2010; PATUELLI et al., 2008; HATZICHRISTOS, 2004), na simulação de dinâmicas temporais do uso/cobertura do solo em áreas florestais (NAGABHATLA, et al. 2012; RUHOFF et al., 2010; PÉREZ-VEGA, et al., 2012) e em áreas urbanas (MISHRA et al., 2014; CHU, et al., 2013; LIU e SETO, 2008; WANG e MOUNTRAKIS, 2011; ISLAM e AHMED, 2011; FERNANDES et al., 1996).

Como exemplo de plataforma GIS que aplica a técnica de Learning Machine – Redes Neurais na modelagem e projeção de uso do solo cita-se o Land Change Modeler for Ecological Sustainability (LCM-Idrisi).

Podemos dizer que o LCM (apresentado na seção 2.3.2.1) é um modelo Learning Machine, pois usa de Redes Neurais na definição das regras de Transição. Para projeção do uso do solo baseia-se nos princípios da Cadeia de Markov. O LCM também é um Módulo que apresenta

rotinas de planejamento estratégico como ferramenta de apoio aos *Planning Support System* (PSS). Desta forma, antes de demonstrar como funciona um modelo baseado em Redes Neurais, é necessário apresentar o método de Cadeia de Markov, comumente usado com Autômatos Celulares e explicar o que vem a ser o Sistemas de suporte ao planejamento (*Planning Support System*).

2.3.2 Metodologia de projeção do uso do solo baseada em Markov Chain e Cellular Automata

2.3.2.1 Markov Chain

Um processo de Markov é um processo estocástico cujo comportamento dinâmico é tal que as distribuições de probabilidade para o seu desenvolvimento futuro depende somente do estado presente, não levando em consideração como o processo chegou em tal estado (DIMURO et al., 2002; ANDERSSON, et al., 2002; LI e ZHANG, 2010; HERMANNNS, 2002).

Se o espaço dos estados é discreto (enumerável), então o modelo de Markov é denominado de “Cadeia de Markov”. As propriedades desses modelos são estudadas em termos das propriedades das matrizes de transições de estados que são utilizadas na sua descrição. Esta matriz é dinâmica, pois permite que as probabilidades de transição se modifiquem em função do tempo t , onde t é discreto. (EL YACOUBI, 2006; DIMURO et al., 2002).

Cadeias de Markov são modelos matemáticos para descrever processos estocásticos e podem denotadas por:

$$\Pi_{(t+1)} = P^n \cdot \Pi_{(t)}$$

Equação 9

onde $\Pi(t)$ é o estado do sistema no tempo t , $\Pi(t+1)$ é o estado do sistema após o intervalo $t+1$ e P^n são os estados passíveis de acontecer, que são representados em matrizes de possibilidades de transição. Essas matrizes de transição representam a possibilidade de um determinado estado i permanecer o mesmo ou mudar para o estado j durante o intervalo de tempo $t \rightarrow t+1$.

As probabilidades de transição são usualmente derivadas de amostras relativas a um certo intervalo de tempo. Cadeias de Markov de 1ª ordem assumem que o estado futuro do sistema depende apenas do seu estado presente e das possibilidades de transição, sendo independente da trajetória que o levou aquele estado. Este modelo não ignora o passado, mas assume que

toda a informação do passado está concentrada no presente. Desta forma, as interações são instantâneas, sendo irrelevante o tempo de permanência das variáveis em cada estado (SOARES FILHO, 1998).

Esta metodologia aplicada isoladamente aos estudos geográficos apresenta algumas limitações que devem ser consideradas: o fato de desconsiderar os processos que levaram ao atual padrão de conformação da paisagem; assumir que os fatores que levaram às mudanças identificadas no período analisado continuarão a atuar na projeção futura com mesma força e intensidade; desconsiderar a questão espacial, o que torna essa técnica aplicada isoladamente desaconselhável para estudos onde a localização geográfica é um fator importante. Além disso, não é aconselhável usar Cadeia de Markov para dados de amostras escassos ou dados temporais com intervalo de longa data (relação de dependência entre os dados):

However, for conditional Markov chain simulation of categorical spatial variables (e.g., various landscape types) based on sparse sample data, one-step TPMs are not sufficient anymore because transition probabilities at different lag distances are needed for estimating the states at unsampled locations. (LI & ZHANG, 2010)

Portanto, neste trabalho apresentaremos as possibilidades de aplicar esta técnica em conjunto com a de Autômato Celular, a qual considera a questão espacial. Como exemplos de plataformas que oferecem a possibilidade de elaborar a Matriz de probabilidade de mudança baseado em Cadeia de Markov são: MARCA – Markov Chain Analyzer; MatLab, R ou SPSS, os quais podem ser integrados a uma plataforma GIS, ou o IDRISI (*Markov Chain*) e Dinâmica, que já apresenta os resultados em formato raster.

No IDRISI, o módulo MARKOV apresenta seus resultados baseados no princípio em que “one in which the state of a system at time 2 can be predicted by the state of the system at time 1 given a matrix of transition probabilities from each cover class to every other cover class” (EASTMAN, 2012b). Desta forma, o módulo MARKOV usa como input dois mapas de uso/cobertura do solo e gera como resultados a matriz de probabilidade de mudança (tabela 2 e 3) e as imagens de probabilidade de mudança por categoria (Fig. 14, 15, 16 e 17).

- a) Matriz de probabilidade de mudança: Expressa as chances (em percentual) que o pixel de uma determinada classe tem de mudar para outra classe ou permanecer na mesma no tempo 2.

Tabela 2: Exemplo de Transition probability matrix – Markov/Idrisi Selva

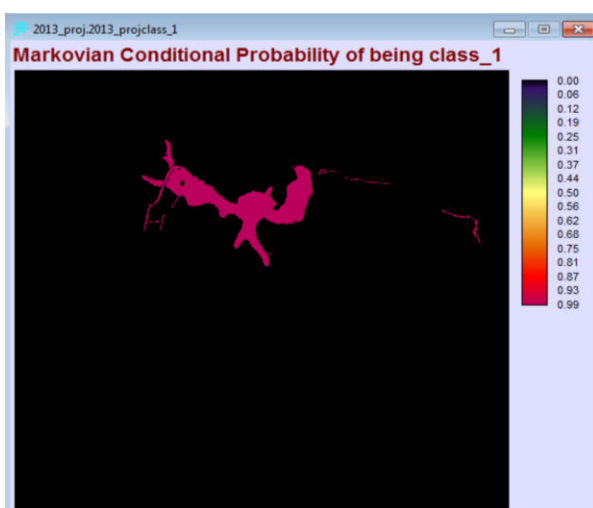
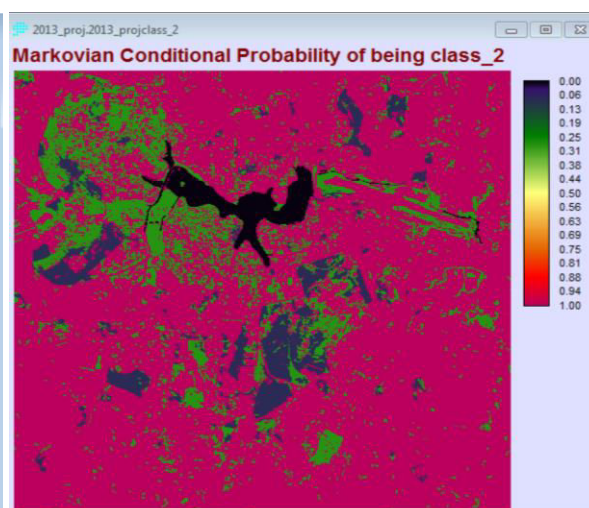
	Classe 1	Classe 2	Classe 3	Classe 4
Classe 1	0.8454	0.1546	0	0
Classe 2	0.05	0.85	0.05	0.05
Classe 3	0	0.1501	0.7143	0.1356
Classe 4	0	0.3934	0.0014	0.6052

- b) Matriz de área de transição: Expressa a área total (em pixels) que tenderá a mudar para outra classe ou permanecer na mesma no tempo 2.

Tabela 3: Exemplo de Transition areas matrix – Markov/Idrisi Selva

	Classe 1	Classe 2	Classe 3	Classe 4
Classe 1	69311	12673	0	0
Classe 2	140067	2381143	140067	140067
Classe 3	0	30432	144808	27490
Classe 4	0	212371	752	326749

- c) Imagens de probabilidade de mudança condicionais: para cada classe de uso do solo é apresentado uma imagem com a probabilidade de mudança espacializada numa escala normalizada de 0 (zero) a 1 (um), onde Zero seria probabilidade nula de mudança e 1 elevada probabilidade de mudança. São chamadas de mudanças condicionais pois a mudança está condicionada á classe inicial.

**Figura 14:** Probabilidade Condicional de se tornar ou permanecer como classe 1 de acordo com a Cadeia de Markov.**Figura 15:** Probabilidade Condicional de se tornar ou permanecer como classe 2 de acordo com a Cadeia de Markov.

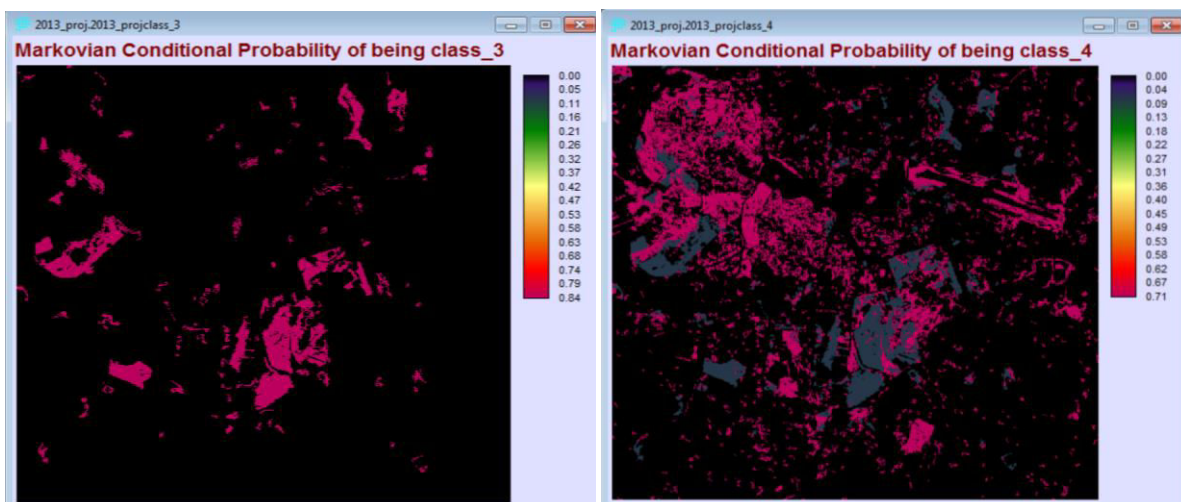


Figura 16: Probabilidade Condicional de se tornar ou permanecer como classe 3 de acordo com a Cadeia de Markov

Figura 17: Probabilidade Condicional de se tornar ou permanecer como classe 4 de acordo com a Cadeia de Markov

2.3.2.2 Cellular Automata

Um dos elementos espaciais básicos que fundamenta a dinâmica de muitos eventos de mudança é a proximidade: áreas terão uma maior tendência para mudar para uma classe quando elas estão perto de áreas existentes da mesma classe. Estas tendências podem ser modeladas eficientemente utilizando autômatos celulares.

Um autômato celular é uma entidade celular que varia seu estado de forma independente, considerando apenas o seu estado anterior e o estado de seus vizinhos imediatos de acordo com uma regra específica (BATTY, et al., 1999; BURROUGH, 1998; ROY, 1996; ENGELEN, 1995; CÂMARA, 1996; O'SULLIVAN & TORRENS, 2000).

A metodologia dos Autômatos Celulares propõe uma rede regular de células idênticas, onde cada uma das quais pode estar em um de um número finito de estados discretos, em intervalos de tempo discretos, na sua evolução. Neste modelo, parte-se de um estado inicial aleatório, onde com o passar do tempo ($T1 \rightarrow T2$), novas células nascem e algumas morrem. O que determina o estado de uma célula é sua vizinhança que, neste caso, é definida por, no mínimo, quatro células adjacentes e as regras de transição, que podem ser identificadas por outras metodologias que não AC. Desta forma, parte do princípio que padrões espaciais globais emergem de ações locais (PONTIUS JR. et al, 2008; COUCLELIS, 1985; TOBLER, 1979; O'SULLIVAN & TORRENS; 2000; GEOGRAPHICAL SCIENCES COMMITTEE, 2014);

A Figura 18, adaptada de Umbelino & Barbieri (2010), Leão (2002), Polidori (2004) e Khun

(2005), apresenta a lógica de funcionamento de um Autômato Celular básico e ilustra sua regra de transição. Primeiro é apresentado um estado inicial, que consiste na distribuição espacial das células nas categorias “vazio” ou “ocupado”, em um tempo inicial (t). Depois, é apresentado o estado destas células em um intervalo de tempo ($t+1$ e $t+2$). Estas seqüências são o resultado da aplicação da regra de transição no espaço celular. O AC analisa a vizinhança de cada célula “vazia” de acordo com a regra: “Se existirem três ou mais células “vazias” na vizinhança, a célula central é convertida de “vazia” para “ocupada”, ou caso contrário, ela permanece ‘vazia’”. A simulação é finalizada quando todas as células do espaço geográfico são analisadas e adequadas à regra de transição, gerando um novo estado global que torna-se a base para a próxima simulação (Leão, 2002).

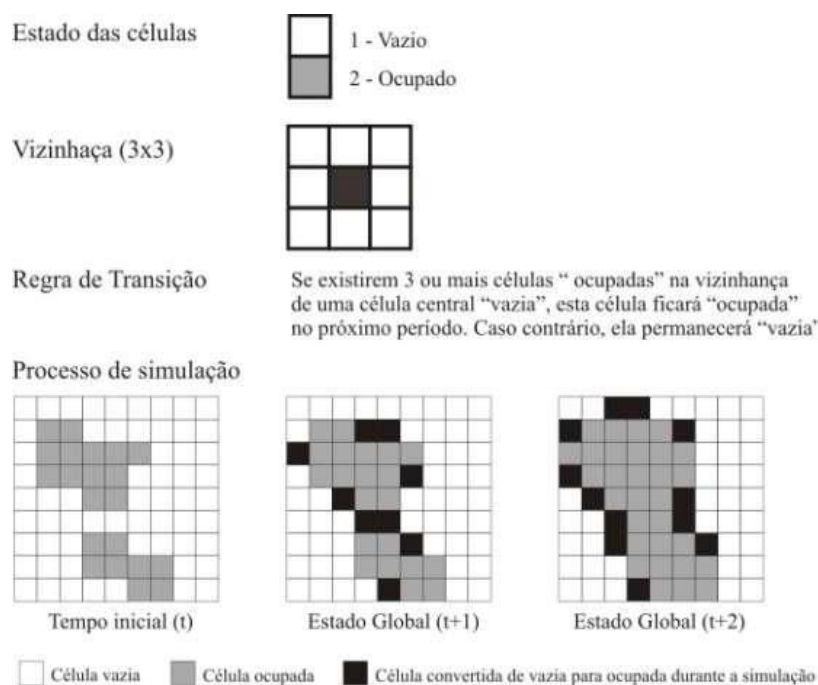


Figura 18: Lógica de funcionamento de um Autômato Celular simples

Os AC funcionam como um jogo, onde as regras mais simples se interagem e podem determinar as formas mais complexas e imprevisíveis de evolução do sistema. Este sistema foi inicialmente apresentado por John Conway, no “*Game of Life*” no qual o jogo é formado por regras simples que aplicadas repetidamente sobre estados aleatórios, produzem resultados semelhantes à forma como certos sistemas evoluem no mundo real (ROY, 1996). Para os estudos na representação geográfica, este se iniciou na Geografia Quantitativa, através do trabalho de Waldo Tobler, que em 1979 começou a explorar os modelos de autômatos em sistemas geográficos e veio mais tarde sugerir que *“the geographic phenomenon could be translated into a cellular array and explored through CA mechanisms based on*

neighbourhood types and transition rules", levando à publicação do precursor artigo "*Cellular Geography*" (TOBLER, 1979).

Esta nova abordagem começou a influenciar a modelagem urbana na década de 1980 e logo se tornou um paradigma dominante (KIM & BATTY, 2011). Foi Couclelis (1985) quem apresentou pela primeira vez um modelo hipotético baseado em AC para um contexto urbano, explorando como as mudanças nos estados de células individuais podem representar mudanças urbanas em grande escala. O objetivo com estes modelos era de encontrar, na estrutura espacial, correlações fortes o suficiente que os permitissem identificar as regras de mutação de um estado para o outro e que, por sua vez, poderiam ser simples (BATTY, 2007a).

Segundo Kim & Batty (2011), a estrutura central dos modelos de Autômatos Celulares apresentam as seguintes características:

- Célula: estrutura computacional básica (pixel). A resolução espacial deve ser informada.
- Tamanho da matriz: estrutura bidimensional (número de linhas e colunas) das células que preenchem o espaço estudado;
- Classificação da célula/pixel: um valor de atributo às células relevantes é dado de 0 a 255.
- Regras de transição: as condições que regem a mudança de um estado a partir de uma célula para outra. É tipicamente definida pelos estados de células vizinhas, no caso de sistemas de Autômatos Celulares simples.

Com base em tais fundamentos do sistema de Autômatos Celulares, a dinâmica do espaço é determinada em conjunto por uma série de funções e métodos adicionais, a fim de capturar o comportamento realista do sistema. Blocos básicos de construção são:

- As condições de adequação, (identificar o que impede tal célula de mudar seu estado inicial);
- As regras de alterações no espaço (identificar o que faz tal célula alterar seu estado inicial);
- Os coeficientes de alterações (identificar a intensidade do fenômeno para que ocorra a alteração);
- As regras de auto-modificação.

Esta metodologia também apresenta algumas limitações, como desconsiderar os processos que levaram ao atual padrão de conformação da paisagem, e assumir que os fatores que levaram às mudanças identificadas no período analisado continuarão a atuar na projeção futura, assim como na Cadeia de Markov. O fato de considerar o estado dos seus vizinhos em sua configuração espacial é o que diferencia o Autômato Celular da Cadeia de Markov e faz esse método ser considerado não-linear. Outro questionamento a esta técnica se dá na rigidez com que o tempo é tratado nos AC, ao trabalhar com sistemas urbanos, uma vez que vários processos tem sua dinâmica temporal altamente flexível e em diferentes escalas, tais como a geotécnica, a ecológica, a política, a diária.

Devemos considerar ainda a questão da resolução espacial do mapeamento urbano, o qual deve ser mais detalhado possível e, que dependendo da escala dos dados disponíveis podem impossibilitar a representação de estruturas importantes da paisagem e que interferem na sua dinâmica. Além disso, a baixa resolução espacial implica em um elevado índice de mistura do pixel, o que pode comprometer a qualidade do modelo e conseqüentemente de seus resultados. Outro fator a ser discutido no AC formal é a noção de vizinhança. No modelo inicial, a noção de vizinhança é considerada para as 4 ou 8 células imediatamente vizinhas na matriz (Figura 19). Entretanto, no espaço urbano, este modelo pode se mostrar ineficaz, pois algumas atividades urbanas influenciam áreas superiores às quadras vizinhas. Assim, é necessário pensar na flexibilidade da área de influência, considerando a influência da ação à distância (O'SULLIVAN & TORRENS, 2000).




Figura 19: Diferentes noção de vizinhança consideradas em Autômato Celular

Mas apesar destas limitações, nos últimos anos, os conceitos de autômatos celulares têm sido utilizados para modelar fenômenos como o espalhamento de epidemias (MELOTTI, 2009; SASSO, et al., 2004), desmatamento na Amazônia (XIMENES et al., 2008; SOARES-FILHO et al., 2003), dinâmicas de mudança no uso do solo em áreas agrícolas (MACEDO et al.,

2013; KAMUSOKO, COURAGE et al., 2009), simulação de tráfego e transporte (LIMA, 2007; SUN et al., 2012), dinâmicas de mudança no uso do solo urbano (COUCLELIS, 1997; BATTY, et al 1999; BURROUGH, 1998; ROY, 1996; ENGELEN, 1995; CÂMARA, 1996; ALMEIDA et al., 2003; MEMARIAN et al., 2012, FUGLSANG et al., 2013; MARIA DE ALMEIDA, et al., 2003; MITSOVA et al., 2011; ONSTED e CHOWDHURY, 2014; PERES e POLIDORI, 2009; VERSTEGEN et al., 2014), além de estudos de população, espaço e ambiente (UMBELINO, G., & BARBIERI, A., 2010) e modelagem de expansão da mancha urbana para regiões metropolitanas (WHITE e ENGELEN, 1997; UMBELINO, 2012; FURTADO & VAN DELDEN, 2011).

Exemplos de plataformas que oferecem esta técnica são: Agent Analyst, Dinâmica, Dynamic Urban Evolution Modeling (DUEM), IDRISI (módulos CellAtom e CA-Markov, sendo somente o CellAtom de metodologia exclusiva de AC), Land Transformation Model (LTM), Simulador do Ambiente da Cidade (SACI), Urban Growth Analysis Tool (UGAT), Metronâmica, LUCIA (Land Use Change Impact Assessment), ou vários outros gratuitos que podem ser encontrados no link a seguir: (http://uncomp.uwe.ac.uk/genaro/Cellular_Automata_Repository/Software.html)

A nível de exemplo apresentaremos como obter uma projeção baseada em AC, no módulo *CA_Markov* do *IDRISI*. Este reúne as metodologias de Cadeia de Markov e Celular Automata em um único processo de projeção, tornando seus resultados mais realistas.

O *CA_Markov* usa como *input* o mapa de uso do solo antigo, a Matriz de área de transição (tabela 3) e as Imagens de probabilidade de mudança condicionais (Fig. 14, 15, 16 e 17), ambas *outputs* do módulo *MARKOV*. É possível ainda substituir as Imagens de probabilidade de mudança condicionais por variáveis explicativas que o Geodesigner ache mais conveniente. Para determinar a transição dos pixels considerando o estado de vizinhança, é usado um filtro de 5x5, ou seja, o estado futuro do pixel central é influenciado pelo estado atual dos 24 pixels vizinhos.

Na projeção modelada, deve-se informar os passos temporais ou o número de interações que devem ocorrer aplicando a metodologia de Automato Celular. O número total de interações é baseado no número de passos temporais que o usuário definir para a sua projeção. Por exemplo, se a projeção será de 10 anos para o futuro, então o usuário deve informar ao software que este deve completar a projeção em 10 passos.

Dentro de cada iteração, todas as classes de cobertura do solo normalmente perdem área para uma ou mais das outras classes (e também podem ganhar área à partir de outras). Assim, no âmbito da consideração de cada iteração, a classe requerente adquire terra do uso inicial com base no mapa de aptidão (construído externamente ao processo), ou com base nas Imagens de probabilidade de mudança condicionais. Uma vez que haverá comumente competição por parcelas específicas, esse processo de alocação de terras é realizada por meio de um procedimento de atribuição de multi-objetivo.

The Cellular Automaton component arises in part from the iterative process of land allocation, and in part from a filtering stage with each iteration that reduces the suitability of land away from existing areas of that type. By default, the module uses a 5x5 mean filter to achieve this contiguity constraint. By filtering a Boolean mask of the class being considered, the mean filter yields a value of 1 when it is entirely within the existing class and 0 when it is entirely outside it. However, when it crosses the boundary, it will yield values that quickly transition from 1 to 0. This result is then multiplied by the suitability image for that class, thereby progressively down weighting the suitabilities as one moves away from existing instances of that class. Note that it is possible to apply a different filter by specifying an alternative filter file (.fil). Also note that class masks are defined at each step to incorporate new areas of growth. CA_MARKOV is computationally intensive—a typical run might involve several thousand GIS operations. (EASTMAN, 2012b).

O resultado final apresentado é a imagem projetada do uso do solo, a qual ainda deve ser calibrada e validada.

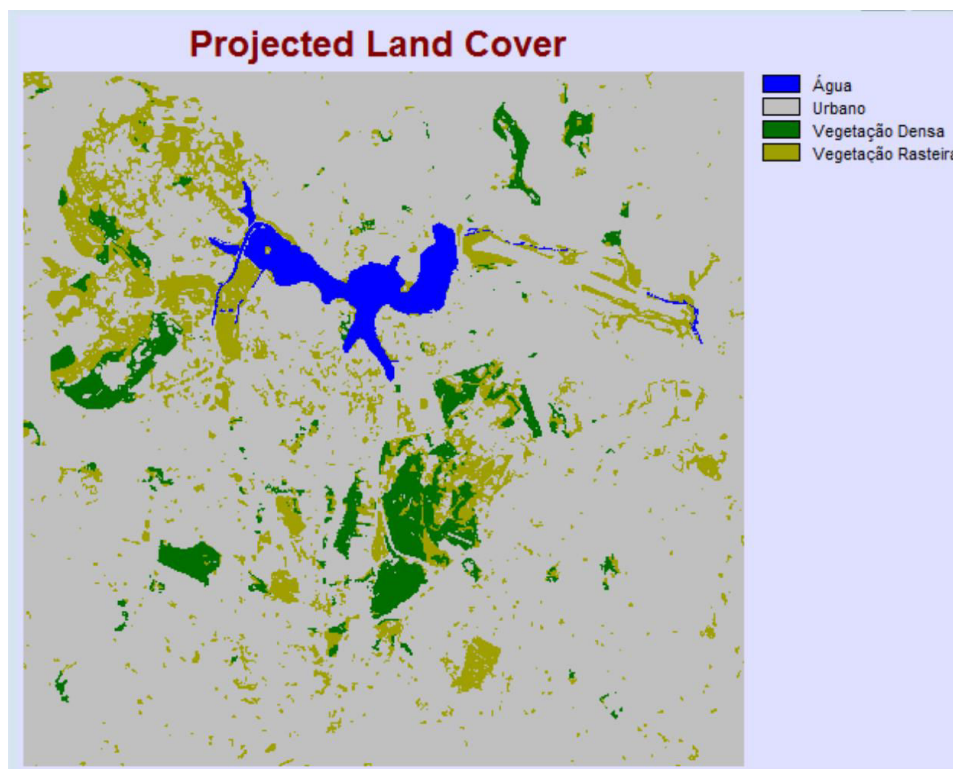


Figura 20: Uso do solo da regional Pampulha/BH projetado usando CA_MARKOV

2.3.2.3 Agent-based Model – Modelagem baseado em Agentes

O paradigma da geossimulação demanda explicitamente a representação do espaço, o comportamento espacial dos objetos e seus relacionamentos espaciais. Assim, a modelagem de indivíduos configura-se como uma das classes de sistemas autômatos. Como sistema autômato, os agentes também especificam o estado autômato e as regras de transição, de forma a permitir a interpretação do comportamento autônomo dos agentes (MAES, 1995).

Assim como não existe uma definição precisa para o termo agente também não há para a modelagem baseada em agentes (MBA). É possível encontrar inclusive algumas variações de nomes, tais como: sistemas baseados em agentes (agent-based systems), modelagem baseada em indivíduos (individual-based modeling), ou ainda, Sistemas multi-agentes (BATTY, 2007a; BONABEAU, 2002; GILBERT, 2008; DEANGELIS et al., 1992; SANDERS et al., 1997).

Cada vez mais os sistemas multi-agentes são utilizados para a resolução de problemas complexos e de natureza descentralizada. A característica primordial de um Modelo Baseado em Indivíduos (MBI) ou agentes é, segundo Giacomini (2007) é “a utilização do indivíduo como unidade básica”.

Para Jorgensen (1994), neste sistema a população não é mais representada por uma variável contínua ou variável de estado, como é comumente denominada na literatura. Nos modelos tradicionais, as variáveis de estado (ex. densidade populacional) podem ser pensadas como compartimentos que aumentam e diminuem de nível conforme as regras definidas por sistemas de equações diferenciais, que modelam as taxas de crescimento populacional. No Sistema Multiagente (SMA), estes trabalham de forma cooperativa onde cada um resolve uma parte do problema, ou seja, a população é exatamente o conjunto das entidades discretas das quais é composta: os indivíduos.

Em um MBI, os indivíduos são representados explicitamente. O indivíduo é o objeto ou compartimento para o qual as regras do modelo são voltadas. Ele carrega tantas informações quantas forem convenientes para o interesse do modelador (GIACOMINI, 2007).

Existem basicamente duas categorias de características associadas aos indivíduos: aquelas inatas, ou seja, adquiridas logo no nascimento e que moldam todo o potencial de desenvolvimento e interações do indivíduo com o meio; e aquelas descritoras de condição, que influenciam na dinâmica, mas que são influenciadas pelas características inatas e pela interação com o meio. O detalhamento em um MBI depende geralmente da quantidade de características associadas ao indivíduo. A dinâmica de natalidade, crescimento e mortalidade é resultado de um conjunto de regras que associam as características individuais à forma como os indivíduos interagem entre si e com o meio. Por meio desses processos, na escala elementar do indivíduo, emergem naturalmente os padrões observáveis em níveis maiores de organização: populacional, comunitário ou até ecossistêmico (DE ANGELIS et al., 1994).

Nesta abordagem o espaço é representado por um mosaico de células, geralmente de tamanhos e formatos idênticos (regular tessellations). Uma consideração importante nas aplicações geográficas é que o indivíduo/agente é capaz de uma ação de mobilidade, uma possibilidade de mudar seu próprio estado e dos vizinhos, assim como sua localização no espaço de acordo com o lugar que residem, movimentos migratórios, entre outros. Ou seja, na modelagem baseada em indivíduos a relação de vizinhança não é fixa, como demonstra a figura 21.

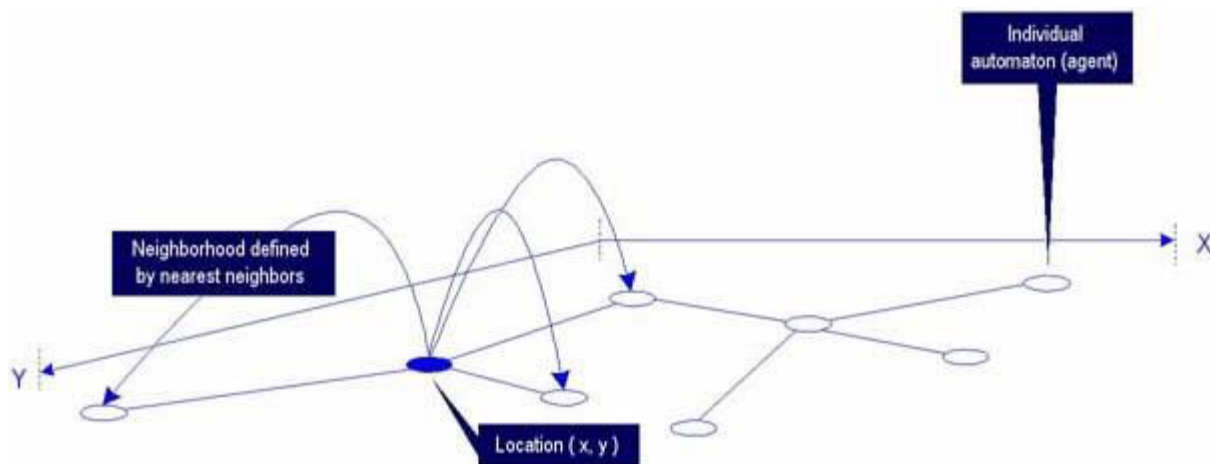


Figura 21: Características dos sistemas multi-agentes

Embora seja classificado como um tipo de sistema autômato, a modelagem baseada em agentes se diferencia do Autômato Celular nos seguintes pontos (vide tabela 04):

Tabela 4: Comparação entre CA e MSA

Características	Autômato Celular	Agentes ou Indivíduos
Variável	Contínua	Discreta
Vizinhança	Regular: refere-se às células vizinhas	Aleatória: Vizinhos possuem localização aleatória de acordo com a capacidade de movimentação no espaço do agente
Relacionamentos espaciais	Pouco flexíveis: referem-se às células vizinhas	Muito flexíveis: referem-se aos agentes com quem tem relacionamentos espaciais e não às células vizinhas. Estes podem estar em qualquer lugar na matriz.
Tempo	Passos discretos	Passos discretos
Regras de transição	Na célula	No agente

Uma pergunta que podemos fazer é: Quais as vantagens de se usar a modelagem baseada em agentes (e SMA)? A resposta seria a de que a modelagem baseada em agentes complementa e melhora a abordagem tradicional (COLELLA et al., 2001). Podem descrever propriedades macroscópicas de um sistema que já são conhecidas, mas não explicam a origem dessas propriedades;

A modelagem baseada em agentes geralmente envolve um ou mais tipos de agentes, em quantidades bastante variáveis em cada classe ou tipo, melhorando o estudo de populações heterogêneas. Está geralmente interessada na dinâmica entre os agentes e nos diferentes tipos de dinâmicas que podem resultar em diferentes ambientes. Bonabeau (2002) relata que a modelagem baseada em agentes apresenta alguns benefícios em relação a outras técnicas de modelagem, pois: (1) permite capturar fenômenos emergentes; (2) fornece uma descrição natural de certos tipos de sistemas; (3) é flexível.

De Lima, T. et al (2009) identificam ainda algumas situações potenciais para utilização da MBA, tais como: quando os agentes possuem um comportamento complexo, incluindo aprendizagem e adaptação; quando as interações entre os agentes são complexas, não-lineares e descontínuas. Para o Geographical Sciences Committee (2014), o uso da modelagem baseada em agentes é indicado para explorar os processos de mudanças no uso do solo, explorar os efeitos de fatores externos ao sistema no sistema, sobretudo nos lugares onde estes fatores externos ainda não atuaram; explorar cenários futuros onde os padrões passados são indicadores fracos das mudanças futuras. No que se refere à sua aplicação nos estudos urbanos, a Modelagem baseada em Agentes apresenta algumas vantagens, como nos relata Torrens (2000):

First is their ability to model multiple autonomous units (i.e. governed without the influence of centralized control), situated within a model or simulation environment. Animate (mobile) agents can be considered as agents who move about the systems, such as pedestrians. In contrast, inanimate (immobile) agents such as land parcels do not move but can change state. Secondly, ABM allows for the representation of a heterogeneous population therefore the notion of a mean individual is redundant, a common assumption of past urban models (TORRENS, 2000).

A Thomas Schelling (1971) é creditado o desenvolvimento do primeiro modelo social baseado em agente, no qual os agentes representam as pessoas e as interações entre agentes representam um processo socialmente relevante. *Schelling's (1971) model demonstrated that stark geographical segregated patterns can emerge from migratory movements among two culturally distinct, but relatively tolerant, types of household via mild discriminatory choices by individuals (CROOKS, 2010).*

Entretanto, a modelagem baseada em agentes não ocupou um lugar de destaque na literatura geográfica até meados dos anos 1990, quando Epstein e Axtell (1996) estendeu a noção de modelar as pessoas às crescentes sociedades artificiais. O objetivo era compreender o

surgimento de padrões, tendências ou outras características observáveis em uma sociedade e sua geografia. O modelo *Sugarscape* de Epstein e Axtell demonstrou que os agentes poderiam surgir com uma variedade de características e comportamentos sugestivos de uma sociedade rudimentar, por exemplo, em termos de padrões de morte, doença, comércio, saúde, cultura, conflito, guerra, etc (CROOKS, 2010).

A aplicação da modelagem baseada em agentes tem sido praticada em estudos na área de biologia e ecologia (WERNER et al., 2001; GRIMM, 1999), no mapeamento de alianças entre nações durante a Segunda Guerra Mundial (AXELROD e BENNETT, 1993); modelagem de processos econômicos que interagem com sistemas dinâmicos de agentes (TESFATSION and JUDD, 2006); tamanho da empresa e distribuições taxa de crescimento (AXTELL, 1999; AXELROD, R. 1997); nas variações de preços na negociação de ações no mercado (BAK et al., 1999); comportamentos de voto nas eleições (KOLLMAN et al., 1992); identificando e explorando o comportamento em campos de batalha (ILACHINSKI, 1997); padrões espaciais de desemprego (TOPA, 2001); redes de comércio (EPSTEIN e AXTELL 1996); conselhos empresariais e padrões de indústria (AXELROD, 2006); redes sociais de grupos terroristas (NORTH et al., 2004), que visem a compreensão das dinâmicas espaciais de sociedades primitivas (KOHLENER e GUMMERMAN, 2001), reconstrução arqueológica de civilizações antigas (AXTELL et al., 2002); distribuições de tamanho-frequência para os engarrafamentos (NAGEL e RASMUSSEN, 1994); mudanças no uso do solo no cerrado brasileiro (RALHA et al., 2013) e em ambiente urbano com diferentes aplicações, tais como: simulação de crimes, aplicações a comportamento de pedestres, de negócios e área comercial; no sistema de educação; desigualdades espaciais na distribuição dos centros de saúde, no mapeamento dos movimentos pendulares diários e fator de escolha da residência, modelagens que integram economia, mercado e mudanças no uso do solo ; (SANDERS et al., 1997; CROOKS, SEE, BATTY (org.), 2012), entre outros.

Como exemplos de plataformas que apresentam a possibilidade de modelagem baseada em agentes são: MASE - Multiagent System for Environmental Simulation (UNB - Brasil); UrbanSim (Waddell 2002), ILUTE (Miller 2004) and DELTA (Simmonds, 1999); TRANSIMS ABM (TRansportation ANalysis SIMulation System); NetLego, entre outros.

Um desafio, comum a todas as técnicas de modelagem, é que o modelo deve ser construído num nível correto de descrição dos fenômenos, usando uma quantidade adequada de detalhes, para servir ao seu propósito. Um desafio a ser superado envolve a utilização da MBA nas

ciências sociais, com aplicações que envolvam seres humanos, devido ao seu comportamentos potencialmente imprevisíveis, de escolhas subjetivas e psicologia complexa, aspectos estes difíceis de quantificar, calibrar e muitas vezes justificar. Outro desafio ainda está relacionado à própria definição da MBA, a qual trata um sistema no nível de suas unidades constituintes e em um intervalo de tempo pequeno o suficiente para se aproximar das dinâmicas temporais reais, o que exige elevado poder computacional e tempo para simulação do modelo, conforme a escala e a complexidade modelada (De LIMA, T. et al., 2009; CROOKS, 2010).

2.3.2.4 O Land Change Modeler (LCM) for Ecological Sustainability – Um Modelo de Simulação da paisagem para sustentabilidade ecológica

O *Land Change Modeler (LCM) for Ecological Sustainability* é um aplicativo comercial desenvolvido pela *Clark Labs* e tem como objetivo a projeção de cenários futuros e a avaliação de impactos de cunho ecológico. Foi desenvolvido inicialmente para aplicações na Ecologia, entretanto tem sido amplamente utilizado para a modelagem de mudanças de uso do solo em geral. A interface do *Land Change Modeler (LCM)* é organizada em seis grandes eixos:

- Change Analysis – Analisa as imagens de uso do solo antigas (exige no mínimo 3 imagens para realizar todo o processo de modelagem);
- Transition Potentials—Modela o potencial de transição nos usos;
- Change Prediction—Projeta o curso das mudanças para o futuro;
- Implications- Avalia os impactos de biodiversidade;
- Planning – Avalia as intervenções de planejamento para manter a sustentabilidade ecológica
- REDD Project – Estima a emissões de gases de efeito estufa a partir de projetos REDD.

A entrada dos dados no LCM exige que alguns aspectos sejam considerados, tais como:

- A legenda em ambos os mapas devem ser as mesmas, inclusive com mesma grafia;
- As categorias analisadas em todos os mapas devem apresentar a mesma sequência, por exemplo: se no mapa antigo a categoria urbano recebeu o ID 01 (um), então em todos os mapas o ID para urbano também tem que ser 01 (um), e assim por diante;
- A área delimitada como “fundo” ou não analisada/background deve ser a mesma em todos os mapas e deve apresentar valor zero como ID.

- Todos os mapas devem apresentar a mesma dimensão espacial, incluindo resolução espacial e sistema de coordenadas.

A seguir apresentamos um fluxograma do processo de modelagem no LCM.

Change Analysis, Model Training, and Validation

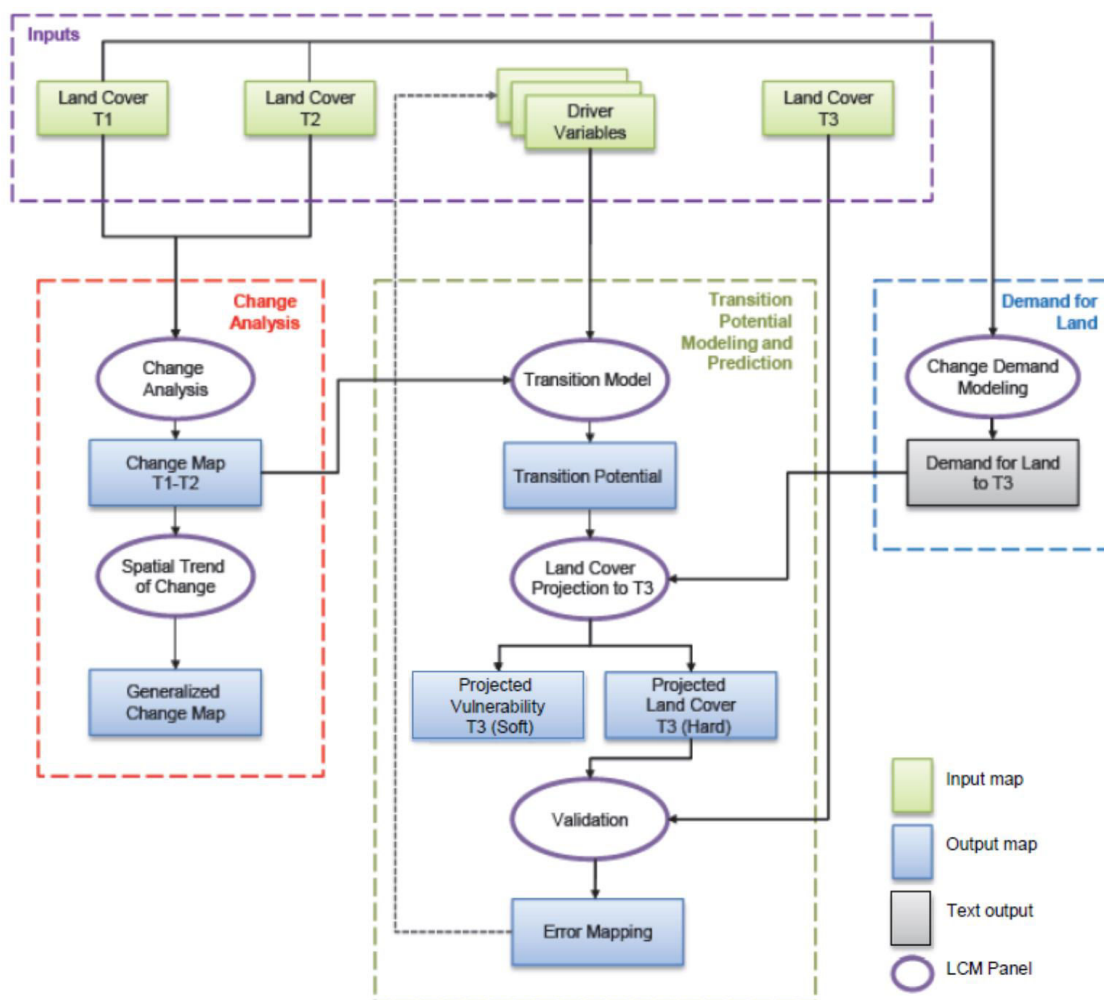


Figura 22: Fluxograma do processo de Análise de Mudanças, Modelos de treinamento e Validação no LCM. Adaptado de (Eastman, J. R. 2012b).

Para usar o LCM é necessário ter como input 03 (três) imagens de uso do solo, todas atendendo os parametros mencionados anteriormente. Para melhor entendimento do processo, vamos considerar que T1 é imagem mais antiga, T2 é a imagem intermediária e T3 é a imagem recente.

O LCM chama de Variáveis Drivers as variáveis que serão usadas para responder pelos processos de mudança nas variáveis de uso do solo. Seria as variáveis independentes do

processo de Regressão Linear, Variáveis Explicativas ou camadas intermediárias das Redes Neurais. Todas essas variáveis devem estar normalizadas numa mesma escala numérica, (por exemplo, de 0 a 1, onde 1 indica o maior potencial de transformação do uso do solo e 0 o menor potencial).

No *Change Analysis* será apresentado uma série de gráficos que ajudarão a compreender o comportamento da mudança por categoria e, um mapa de mudanças e permanência dos usos.

- *Gains and Looses by Category*: informa, de acordo com a unidade de mensuração informada (Km2, m2, ha, pixel, etc), as perdas e ganhos de cada categoria;
- *Net change by category*: considerando as perdas e ganhos, informa o saldo final (se mais perdeu, ou se mais ganhou);
- *Contributors to net change experienced by*: Neste item, mostrará a contribuição das outras categorias para as mudanças em uma categoria escolhida, considerando apenas o saldo da mudança.




Figura 23: Mapa de mudanças e permanências do uso do solo

O *Change analysis* ainda apresenta uma série de mapas que auxiliam na compreensão da dinâmica de transformação do uso do solo, como por exemplo: um mapa exclusivo das permanências, um mapa exclusivo das mudanças geral e por categoria, mapa de perdas e ganhos comparando duas categorias ou ainda identificar o *hotspot* da transformação usando um polinômio de 1ª à 9ª ordem. O mapa de mudanças e permanências (Fig. 23) apresenta sua legenda em duas colunas, sendo a primeira correspondente ao ano de 2009, e a segunda ao ano de 2011, neste exemplo. Valores iguais indicam que o uso permaneceu, valores diferentes

indicam a alteração do uso da primeira coluna para a segunda. É usado como dado de entrada no *Transition Model*.

No *Transition Model*, será criado um Submodelo onde o usuário indica todas as transformações na paisagem detectadas nas mudanças dos mapas T1 e T2 e que ele julga importante ser considerada na modelagem do potencial de transformação da paisagem futura.

O mapa de mudanças e permanências, output do *Change Analysis*, entra como input no *Transitions Model* com o intuito de facilitar a compreensão das tendências de transformação. Para tal, aplica-se uma função de transformação no mapa de mudanças e permanências, onde o resultado será um mapa de potencial de transformação baseado exclusivamente nas mudanças observadas. Segundo Eastman (2012b), os log de transformação mais usados são:

- a) O *natural log transformation* quando seus dados no submodelo são predominantemente linearizados, por exemplo, distância das vias, densidade, concentração, etc..
- b) O *evidence likelihood transformation* quando suas variáveis no submodelo são categóricas ou de origem qualitativa.

É possível usar o mapa de saída desta transformação para realizar um teste exploratório das categorias do seu mapa de uso do solo e o quão essas categorias influenciam o processo de transformação. O método estatístico aqui aplicado é o Coeficiente V de Cramer, onde valores baixos de V de Cramer (menor que 0.15) indicam que esta variável pode ser retirada do modelo.

É no *Transition Model* que também entramos com as Variáveis Drivers. Neste momento devemos informar se as variáveis drivers são Estáticas ou dinâmicas. Segundo Eastman (2012b), variáveis estáticas expressam aspectos de adequação de base para a transição em questão, e são imutáveis ao longo do tempo. Variáveis dinâmicas são condutoras dependentes do tempo, tais como a proximidade de desenvolvimento ou infra-estruturas (estradas) e são recalculadas ao longo do tempo durante o curso de uma previsão existente.

Ao rodar o modelo devemos escolher qual método usaremos para calcular o potencial de transição: *MLP (Multi-Layer Perceptron neural network classifier)*, *SimWeight (empirical transition potential modeling procedure)* ou Regressão Logística.

Segundo Eastman (2012b), ambos *MLP* e *SimWeight* usam metade das amostras (pixels que

sofreram mudanças no uso do solo no período analisado) para a calibração/treinamento e a outra metade para validação.

O *MLP* gera associações prévias de classe para cada um dos pixels de validação em cada iteração e relata a precisão global, bem como uma pontuação por potencial de transformação. A pontuação por potencial de transformação representa a diferença entre a precisão calculada utilizando os dados de validação e a precisão esperada, se fosse para obter o valor de forma aleatória nas associações das classes dos pixels validados (EASTMAN, 2012b).

O *SimWeight* calcula o potencial médio de transição entre os pixels que mudou (ou seja, passou pela transição) e o potencial de transição média entre os pixels que não mudaram (persistentes) na classe dos pixels validados. Estes expressam a taxa de acerto e taxa de falso alarme, respectivamente. A diferença entre eles produz o Peirce Habilidade Score - um valor entre 0 e 1 (EASTMAN, 2012b).

Ao rodar o modelo MLP deve-se ater para o valor da Taxa de acurácia, o qual indica o quanto o modelo consegue prever as transições futuras corretamente. Indica-se que este valor seja próximo de 100%. Além disso, quanto mais detalhado for a escala de análise (resolução espacial e número de categorias analisadas), maior número de interações serão necessárias para finalizar o processo de mapeamento do potencial de transformação. Como resultado desta etapa temos os mapas de potencial de transformação por categoria de análise (Fig.24).

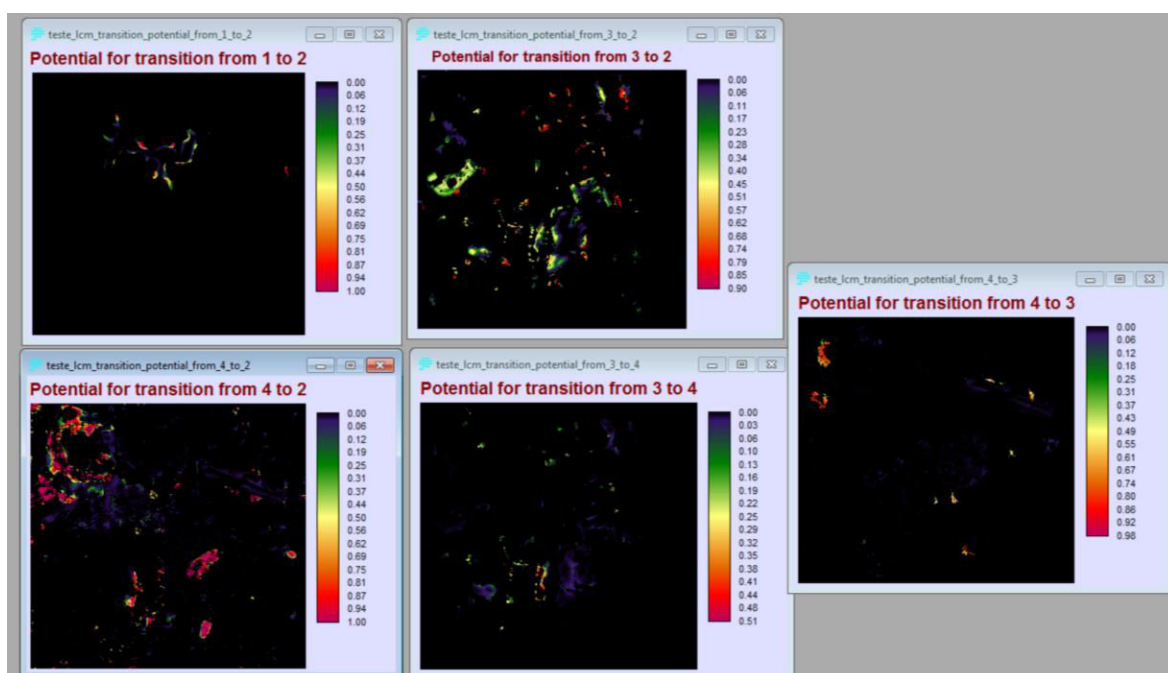


Figura 24: Mapas de potencial de transição calculados através de Redes Neurais (MLP)

A próxima etapa no Modelo é a projeção do mapa T3_projetado. Enquanto as regras de transição foram definidas por Redes Neurais, a quantidade de pixels que sofrerão transformações será definido por Cadeia de Markov ou qualquer outro método externo ao LCM. O mapa T3_projetado será comparado com o mapa T3_real e verificado o percentual de acerto no mapa projetado. Quando o percentual de acerto no mapa projetado for próximo a 100% ou 1, então dizemos que o modelo foi validado e podemos então simular o mapa futuro. O processo de simulação do mapa futuro segue o fluxograma a seguir (Fig. 25):

Land Cover Prediction

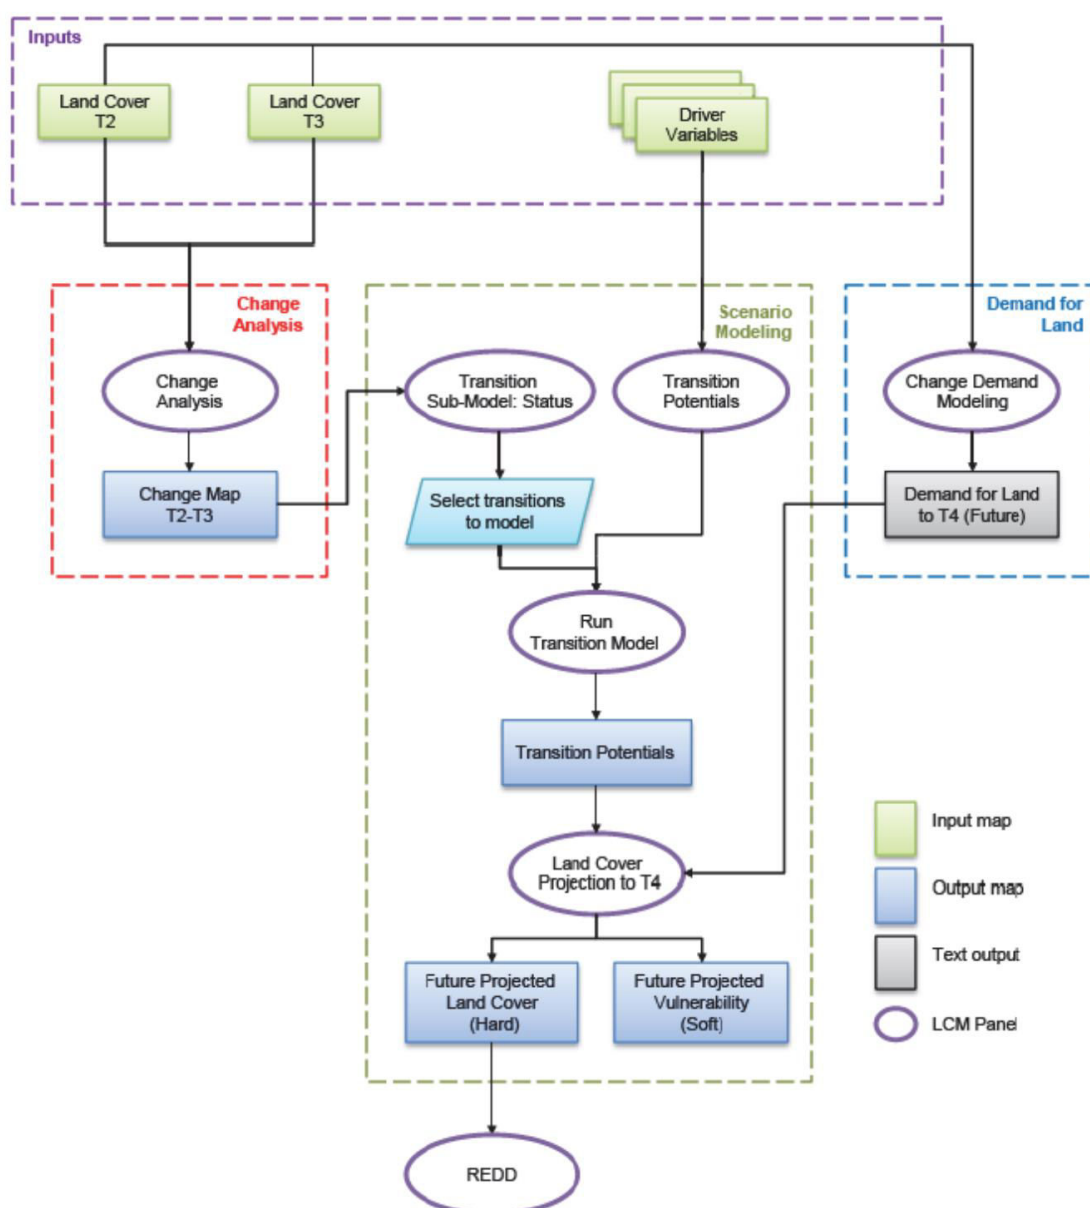


Figura 25: Fluxograma do processo de modelagem futura do uso do solo no LCM. Adaptado de (Eastman, J. R. 2012b).

Usa-se dois mapas de uso do solo de entrada (T1 ou T2 e T3_real) assim como as variáveis drivers. Repete os procedimentos do *Change Analysis*, *Transition Model* e *Change Prediction* com os novos mapas de uso do solo, projetando então o mapa T4_futuro. A taxa de acerto deste mapa refere-se à taxa de acerto alcançada para projetar o mapa T3_projetado. Como resultado apresenta o mapa projetado do Uso do Solo por categoria de legenda e o mapa síntese de probabilidade de mudanças na paisagem.




Figura 26: Outputs do LCM - Mapa projetado do uso do solo e mapa síntese de probabilidade de mudança

O LCM ainda permite incluir nas simulações os dados referentes a projetos ainda em análise ou já aprovados, informar a data a partir de quando estes dados devem ser considerados ativos no modelo (na aba *Planning - Planned Infrastructure Changes*) e avaliar o impacto que estes causarão na paisagem. A inclusão desta ferramenta de simular algo ainda não construído o classifica como um modelo que permite explorar rotinas de planejamento estratégico como ferramenta de apoio ao *Planning Support System* (PSS) ou Sistema de Suporte ao Planejamento.

2.3.2.5 Rotinas de Planejamento Estratégico

Os Sistemas de suporte ao planejamento surgiram no final da década de 1980 como um termo genérico para definir o conjunto de ferramentas computacionais, não integradas em um sistema único, que eram usadas pelos planejadores urbanos e regionais. O uso de ferramentas

computacionais foram aplicadas aos assuntos humanos desde a invenção do computador, em meados do século 20, e já em 1960 os planejadores experimentavam estes sistemas com uma larga escala de dados e simulação. Isso levou imediatamente para sistemas de informação municipais e modelos de uso da terra-transporte que formaram o núcleo da caixa de ferramentas do planejador até o advento de sistemas de informação geográfica (SIG). Na década de 1990, houve um conjunto suficientemente variado de ferramentas informando a maioria das etapas do processo de planejamento técnico. Assim, faz sentido considerar estes coletivamente como sistemas de suporte de planejamento que poderão ser desenvolvidos de forma mais integrada e adaptadas a diferentes contextos em que se faz necessário no planejamento (BATTY, 2007; LIESKE e HAMERLINCK, 2012; ZYNGIER, et al. 2014).

Klosterman (1997) descreve um Planning Support System útil como aquele que permite ao usuário selecionar a ferramenta adequada a partir de uma caixa de ferramentas de planejamento; vinculá-lo ao banco de dados apropriado; realizar os cálculos necessários com base em pressupostos de usuários das condições atuais e futuras; e, apresentar rapidamente os resultados na forma de gráficos, mapas e outros meios de comunicação. Hopkins (1999) define PSS como o fornecimento de "*views and tools for sketch planning, model building, scenario building, evaluation, lineage tracking, and plan-based action*". Brail e Klosterman (2001) descreveram como os Sistemas de Informações Geográficas tornaram-se uma parte importante dos muitos esforços de desenvolvimento dos Planning Support System na academia e no sector privado.

Harris (1989), ao descrever o impacto que o GIS tem no campo do planejamento, argumenta que, "*assim como a gestão requer uma rotina de apoio, o planejamento requer uma rotina de suporte estratégico*", diferenciando conceitualmente os sistemas de apoio á decisão dos sistemas de suporte ao planejamento.

Entende-se por rotina de planejamento estratégico toda e qualquer ação que vise simular em ambiente computacional projetos e decisões políticas ainda não aprovados e/ou implementados no espaço, assim como a apresentação destes resultados estarem focados na comunicação do conteúdo essencial de uma forma fácil e acessível aos diferentes públicos envolvidos no processo de planejamento (diferentes formatos de visualização do dado: vídeos das transformações ao longo do tempo, simulação em ambiente 2D, 3D e 4D - evolução no tempo e no espaço – vertical e horizontal), entre outros.

O uso de rotinas de planejamento estratégico se faz necessário uma vez que os Planning Support System foram desenvolvidos como sistemas integrados aptos para lidar com uma diversa gama de atividades que incluem: planejamento abrangente; alocação de crescimento; planejamento de esboço (*sketch planning processes*); planejamento ambiental; modelagem de uso transporte integrado (*integrated land use-transportation modelling*); modelos de simulação de normativas relacionadas ao uso do solo (*land-use policy simulation models*); visualização de desenho urbano (*urban design*); comunicação entre planejadores e decisores (*communicating urban design to planners and decision makers*); exploração de cenários alternativos com base em classificação e ponderação de pesos de indicadores; planejamento comunitário; gestão de dados, análise, resolução de problemas, design, tomada de decisão, e atividades de comunicação (BRAIL e KLOSTERMAN, 2001; ZYNGIER, et al. 2014).

Segundo Brail e Klosterman (2001), “*a scenario is not a prediction, but rather it is an illustration of contingent events likely to occur if key assumptions come to fruition*”. Para executarmos uma rotina de planejamento estratégico e simular um cenário devemos estruturar o modelo para que este seja capaz de fazer previsões, e estas devem ser calibradas e validadas. Após o modelo ser validado, então cria-se os cenários. Por exemplo: O que aconteceria no uso do solo de uma cidade X se ali fosse construído um novo aeroporto? E se alterássemos o coeficiente de aproveitamento da Lei de Uso do solo? E se duplicarmos tal via, resolveríamos o problema do trânsito? E se...? Cada pergunta “E se...?” corresponde a um cenário passível de ser simulado em ambiente computacional, em algumas plataformas específicas, que oferecem a possibilidade de executar rotinas de apoio ao planejamento estratégico e assim configurar uma das etapas de um Planning Support System.

Alguns exemplos de plataformas que oferecem esta técnica são: Community Viz, Metronâmica, What If, LCM, City Engine, entre outros. No LCM essa ferramenta encontra-se na aba Planning, e chama-se *Planning Infrastructure Change*.

As rotinas de planejamento estratégico associada á simulação de cenários hipotéticos têm sido aplicadas em estudos que envolvem a participação comunitária no processo de planejamento, usando diferentes metodologias, como mostra a Tabela 05.

Tabela 5: Exemplos de aplicações de rotinas de planejamento estratégico

Local	Agentes	Objetivo	Ferramentas
Rijnenburg Polder, Utrecht, Netherlands	Province of Utrecht; City of Utrecht; Hoogheemraadschap De Stichtse Rijnlanden (Regional Water Board); IVAM, University of Amsterdam; MAPSUP	Elaborar propostas de Zoneamento Sustentável para área rural. 700 pessoas envolvidas.	DPL (Sustainability Performance of a Location) developed by IVAM and CommunityViz Version 3.x on a custom-made MAPSUP 'MapTable,' a digital drawing board that is linked to a computer.
Montrose, Colorado	City of Montrose; Winston Associates, Inc.; Foresee Consulting, Inc	Atualização do Plano Diretor de forma participativa. Criou 03 cenários: Tendência atual, Foco nos grandes centros e Foco nos pequenos centros	Growth Challenge Game, keypad polling e Community Viz
Milford, Sussex County, Delaware	Delaware Office of State Planning Coordination; University of Delaware Sustainable Coastal Community (SCC) Initiative; City of Milford, Delaware; University of Delaware and Donley & Associates, Inc.	Elaboração de Plano Diretor de forma participativa: elaboração de visualização 3D de cada tipologia de Zoneamento para facilitar a compreensão do que é permitido em cada zoneamento. Simulação de 03 cenários: "Current Trends," "New Community," e "Suburban," com os impactos demográficos associados a cada cenário.	CommunityViz® Version 4.1, including Scenario 360 and Scenario 3D; Google SketchUp and Google Earth Pro; ArcGIS 9.3.1
Lomianki, Poland	Community of Lomianki; Centrum Gospodarki Przestrzennej	Elaborar 3 cenários alternativos de crescimento da cidade de Lomianki, a qual possui um parque considerado Reserva da Biosfera pela UNESCO. Cenário 1: refletiu um desenvolvimento no âmbito do plano de crescimento atual. O segundo cenário refletiu uma abordagem mais conservadora focada na redução dos efeitos indesejáveis do desenvolvimento. O terceiro cenário mostra uma substancial concentração do desenvolvimento, com aumento da densidade em algumas áreas com realocação das comunidades.	CommunityViz e ArcGIS

US Highway 521/SC 9 Corridor, Lancaster County, South Carolina	Lancaster County; City of Lancaster; Lancaster County Economic Development Commission; South Carolina Department of Commerce; Catawba Regional Council of Governments; Kimley-Horn & Associates, Inc.; Arnett Muldrow and Associates, Inc.; Warren & Associates, LLC	Avaliação das dinâmicas do Uso do solo com a Implantação de uma nova rodovia de Fluxo rápido.	CommunityViz 3.1, including the Suitability Wizard; desenvolvimento de um jogo ‘chip game;’ atividade com a comunidade envolvendo o jogo, o desenvolvimento de workshops públicos; reuniões das partes interessadas; uma pesquisa de preferência visual; questionários e um site do projeto.
Grand Junction, Mesa County, Colorado	City of Grand Junction; Mesa County; Winston Associates; Foresee Consulting, Inc.	Elaboração de propostas de Plano Diretor de forma participativa;	Growth Challenge Game, keypad polling e Community Viz; atividade com a comunidade envolvendo o jogo, o desenvolvimento de workshops públicos; reuniões das partes interessadas; site do projeto, divulgação nas mídias de radio e televisão e jornal local.

Fonte: <http://placeways.com/PDFs/planning/>

2.4 CALIBRAÇÃO E VALIDAÇÃO

O processo de calibração e validação de um Modelo de Simulação não é muito claro para muitos profissionais. Em vários artigos, os pesquisadores não explicam como se deu essa etapa, apenas dizem que o modelo foi calibrado e validado. Existe inclusive um questionamento sobre qual o melhor índice a ser adotado para se considerar que o modelo foi validado, assim como qual o valor é considerado “aceitável”.

A etapa de calibração do modelo é a etapa mais demorada no processo da modelagem. Consiste em identificar as variáveis que respondem pela dinâmica do fenômeno estudado, assim como a intensidade e força com que cada uma delas atua na realidade e consequentemente no modelo.

O processo de escolha das variáveis pode usar diferentes metodologias, como a consulta a Multicritérios abordando procedimentos guiados por especialistas (*knowledge driven*

evaluation), procedimentos estatísticos segundo o comportamento dos dados (*data driven evaluation*), ou ainda consulta á bibliografia, embora em casos de aplicações de estudos em espaços urbanos este último seja aconselhável para estudos exploratórios, já que cada cidade evolui de maneira própria.

O processo de validação do modelo consiste em conferir o quanto o modelo construído consegue realizar as previsões de forma correta. O índice mais comumente utilizado para fazer a validação dos mapas de mudanças é o *Kappa index of agreement*.

O Kappa é um índice que tenta descrever a similaridade observada entre o mapa de comparação e o mapa de referência em uma escala em que 1 significa que a similaridade é perfeita e 0 significa que a similaridade observada é pequena, quase nula. Entretanto, o índice de similaridade Kappa é um índice de similaridade geral, o que o classifica como insuficiente para validar um modelo de simulação espacial. Em outras palavras, se comparo um mapa de uso do solo entre 2009 e 2010 eles terão uma tendência a um elevado índice Kappa, já que o intervalo de tempo de comparação é curto e a probabilidade de grandes transformações na paisagem é pequena. Mas ainda assim houveram mudanças e o índice Kappa padrão não consegue nos dizer se o Modelo de Simulação aplicado conseguiu fazer as previsões corretamente pois o Kappa avalia o mapa como um todo e não o percentual de similaridade espacial das mudanças.

If Kappa were to reveal information that is different from proportion correct in a manner that has implications concerning practical decisions about image classification, then it would be vital to report both proportion correct and Kappa; however, Kappa does not reveal such information (PONTIUS Jr. e MILLONES, 2011).

Portanto, se o resultado final da modelagem é um mapa suavizado de potencial de mudança (como por exemplo, os mapas resultados de Regressão Linear ou Cadeia de Markov), Eastman (2012b) aconselha o uso do estimador ROC, que apresenta um fator estatístico para medir a qualidade do ajuste ao método. Se o mapa resultante é dado por tipologias de uso do solo, como os mapas gerados por Redes Neurais ou Autômato Celular, aconselha-se um método que considere os seguintes elementos:

- Identificar o quanto há de permanência entre os dois mapas: Este fator é importante ser avaliado já que ao usar imagens com uma variação temporal pequena ou avaliar uma área de baixa dinâmica espacial, haverá poucas mudanças entre o mapa antigo e o mapa atual;

- O modelo deve ser capaz de avaliar o índice de similaridade entre as mudanças ocorridas e não apenas a similaridade geral entre mapas: o valor aceitável de validação entre os mapas deve ser calculado considerando as mudanças e não a similaridade geral, como atualmente é feito pelo índice Kappa padrão;
- O índice deve avaliar ainda o acerto no que se refere á quantidade e á localização das mudanças. Por exemplo: a mudança real foi de 100 pixels, mas a mudança projetada foi de 97 pixels, isso significa que o modelo tem uma acurácia de 97% no que se refere á quantidade de pixels que mudaram seu estado inicial. Destes 97 pixels que mudaram o estado inicial, 80 foram alocados na posição correta, o que indica uma acurácia de 82,47% no quesito localização.

Desta forma, uma alternativa ao índice Kappa é o *quantity disagreement* e o *allocation disagreement*, proposto por Pontius Jr. e Millones (2011). Os autores definem “*quantity disagreement as the amount of difference between the reference map and a comparison map that is due to the less than perfect match in the proportions of the categories*”, ou seja, quanto maior a diferença entre a quantidade de pixels de a classe de uso no mapa de referência (mapa real) e no mapa projetado, maior o “*quantity disagreement*”.

Pontius Jr. e Millones (2011) definem “*allocation disagreement as the amount of difference between the reference map and a comparison map that is due to the less than optimal match in the spatial allocation of the categories, given the proportions of the categories in the reference and comparison maps*”, ou seja, quanto maior a diferença na localização dos pixels da classe de uso no mapa de referência (mapa real) e no mapa projetado, maior o “*allocation disagreement*”.

O “*quantity disagreement*” e o “*allocation disagreement*”, assim como o índice Kappa padrão apresentam seus resultados numa escala de 0 (zero) a 1 (um), onde quanto mais próximo de um, maior o acerto ou a acurácia do modelo. Desta forma, Pontius Jr. e Millones, (2011) denominam os índices como *Kallocation* e *Kquantity*³.

Atualmente, é possível calcular o *Kallocation* e o *Kquantity* no módulo *VALIDADE* do Idrisi. Segundo Eastman (2012b), o *VALIDATE* apresenta o índice Kappa padrão de validação desmembrado em diferentes componentes, cada qual em uma forma especial do Kappa ou por

³ Para maiores informações em como calcular esses índices, ver Pontius e Millones (2011).

estatística associada baseado no trabalho Pontius (2000 e 2011)⁴:

- *Kappa for no information = Kno*
- *Kappa for location = Klocation*
- *Kappa for quantity = Kquantity*
- *Kappa standard = Kstandard*
- *Value of Perfect Information of Location = VPIL*
- *Value of Perfect Information of Quantity = VPIQ*

Desta forma, sugere-se como valores aptos a validação dos mapas de mudança, percentuais superiores a 90% para *Kallocation* e para o *Kquantity*.

A seguir apresentamos uma tabela síntese que apresenta as principais características dos métodos de modelagem, variáveis drivers e validação.

⁴ [1] Kappa for no information (denoted Kno), [2] Kappa for grid-cell level location (denoted Klocation), and [3] Kappa for stratum-level location (denoted KlocationStrata). All of these statistics are linear functions of points in the VALIDATE output. Specifically, $Kno = \{M(\mathbf{m})-N(\mathbf{n})\} / \{P(\mathbf{p})-N(\mathbf{n})\}$. $Klocation = \{M(\mathbf{m})-N(\mathbf{m})\} / \{P(\mathbf{m})-N(\mathbf{m})\}$. $KlocationStrata = \{M(\mathbf{m})-H(\mathbf{m})\} / \{K(\mathbf{m})-H(\mathbf{m})\}$. Klocation indicates how well the grid cells are located on the landscape. KlocationStrata indicates how well the grid cells are located within the strata (Eastman, 2012).

Tabela 6: Quadro síntese das principais características dos métodos de Modelos de Simulação

MÉTODO	MAPA DE INPUT	TIPO DE MAPA	ITENS DE LEGENDA	VARIÁVEIS EXPLICATIVAS	PADRÃO-PROCESSO	CARACTERÍSTICA	FORMATO	OUTPUT	VALIDAÇÃO
EXOGENOUS QUANTITY	1	COBERTURA DO SOLO	2	0 +	PADRÃO	LINEAR	MATRIZ	MAPA PROJETADO	K_ALLOKATION & k_QUANTITY
REGRESSÃO LOGÍSTICA	1	COBERTURA DO SOLO	2+	1 +	PADRÃO	LINEAR	VETOR / MATRIZ	EQUAÇÃO, MAPA SUAVIZADO DAS PROBABILIDADES DE MUDANÇAS, MAPA DE RESÍDUO, ESTATÍSTICAS	ROC
MARKOV	2+	COBERTURA DO SOLO	2+	0	PADRÃO	LINEAR	MATRIZ	MATRIZ E MAPAS DE PROBABILIDADES DE MUDANÇA	ROC
REDES NEURAIS	2+	COBERTURA DO SOLO	2+	2+	PADRÃO	NAO LINEAR	MATRIZ	MAPA PROJETADO E ESTATÍSTICAS	K_ALLOKATION & k_QUANTITY
AUTOMATO CELULAR	2+	USO DO SOLO/ COBERTURA DO SOLO	2+	2+	PADRÃO	NAO LINEAR	MATRIZ	MAPA PROJETADO	K_ALLOKATION & k_QUANTITY
AGENT-BASED	2+	USO DO SOLO/ COBERTURA DO SOLO	2+	2+	PROCESSO	NAO LINEAR	VETOR / MATRIZ	MAPA PROJETADO	K_ALLOKATION & k_QUANTITY

3. RESULTADOS

A cidade de Belo Horizonte – Minas Gerais, destaca-se no cenário brasileiro no que se refere a trabalhos e pesquisas com o gerenciamento de dados geográficos, uma vez que esta é uma política pública presente na capital desde os anos de 1974, com a criação da PRODABEL. Este cenário, entretanto, não se configura como uma realidade em todas as demais capitais ou municípios brasileiros. Assim, para exemplificar as potencialidades e limitações da aplicação de estudos de simulação urbanística no Brasil, será utilizada a Regional Pampulha, em Belo Horizonte, como um estudo de caso.

Situada na região Norte de Belo Horizonte, a Pampulha surgiu como a representante legítima da modernidade arquitetônica dos anos 1940 no Brasil, quando foi implantado o conjunto urbanístico e arquitetônico da Pampulha, com projetos originais do jovem arquiteto Oscar Niemeyer.

Considerada um ícone da modernidade e das perspectivas desenvolvimentistas de Juscelino Kubitschek, prefeito de Belo Horizonte na época, a Pampulha promoveu a interação entre a arquitetura, artes plásticas e paisagismos. Com a Pampulha, configurou-se uma das mais importantes correntes da arquitetura moderna a serviço da beleza plástica da qual Niemeyer foi o mestre. Junto com a arquitetura de Oscar Niemeyer apresenta-se a pintura de afrescos e azulejos de Cândido Portinari, as esculturas de Ceschiatti, Zamoiski e José Pedrosa, o painel de Paulo Werneck e o paisagismo de Roberto Burle Marx (Prefeitura de Belo Horizonte – 200-).

A Pampulha ainda contou com o represamento do ribeirão Pampulha, o que resultou na barragem da Pampulha, inaugurada em 1943, que buscava fazer o controle das cheias dos tributários e promover o abastecimento da cidade, configurando-se atualmente como uma das maiores bacias hidrográficas metropolitanas do Brasil.

Em setembro de 1965, o Estádio Governador Magalhães Pinto, mais conhecido como Mineirão, foi inaugurado, e em 1980 o Ginásio Poliesportivo do Mineirinho somando estes ao conjunto arquitetônico e paisagístico da Pampulha. Na esteira do complexo arquitetônico, foram incorporados ao projeto o Aeroporto da Pampulha, construído em 1933, o Museu de Arte Moderna (antigo cassino), a Casa do Baile e a Igreja de São Francisco de Assis, projetada na década de 1940, cuja forma arquitetônica reproduz as formas sinuosas das

montanhas de Minas, e é tida como o principal cartão-postal da região. Consagrada em 1960, é considerada um dos maiores exemplos da arquitetura religiosa moderna. Em 1947, a Igrejinha da Pampulha recebeu tombamento federal e, em 1984, pelo Instituto Estadual do Patrimônio Histórico e Artístico de Minas Gerais – IEPHA-MG.

A região destaca-se ainda pela grande aporte de áreas verdes. Além da Fundação Zoobotânica (Zoológico) e do Campus da Universidade Federal de Minas Gerais - UFMG, compõem a região vários parques ecológicos, tais como: Ursulina de Melo, Parque Ecológico da Pampulha, Parque da Guanabara, Fazenda Lagoa do Nado (este é um parque inter-regional) e outros. A Pampulha é, também uma região com vários clubes campestres e de lazer, atraindo um grande número de pessoas durante os fins de semana. Com alto valor imobiliário, a Pampulha tem atraído investidores nos últimos anos, levando a um maior dinamismo na conformação paisagística que apresenta conflitos urbanos, ambientais, arquitetônicos e culturais, todos no mesmo espaço, o que justifica a sua escolha como objeto de estudo neste trabalho.

Para avaliar a dinâmica nas mudanças na cobertura do solo na Pampulha e comparar os diferentes métodos, apresentaremos os seguintes artigos como resultados desta tese:

Artigo 01: Comparação entre métodos de análise multivariada na seleção de variáveis explicativas para compor um Modelo de Simulação da Paisagem – Aplicações na Pampulha, Brasil

Artigo 02: Modelo de Simulação da Paisagem Urbana da Pampulha integrando metodologias de Análise Fatorial, Análise de Multicritério e *Exogenous Quantity* no módulo Geomod/Idrisi

Artigo 03: Construção de Cenários para a Regional Pampulha por Cadeia de Markov e Autômatos Celular: projeção das alterações na cobertura do solo

Artigo 04: Comparação dos métodos “*What if / If then*” por Cadeia de Markov, Autômato Celular e Redes Neurais: simulação de cenários futuros da Regional Pampulha considerando a implantação de uma nova via de fluxo rápido

Artigo 01: Comparação entre métodos de análise multivariada na seleção de variáveis explicativas para compor um Modelo de Simulação da Paisagem – Aplicações na Pampulha, Brasil

Comparação entre métodos de análise multivariada na seleção de variáveis explicativas para compor um Modelo de Simulação da Paisagem – Aplicações na Pampulha, Brasil

Carvalho, G.A.^{1,2*}, Moura, A.C.M.²

¹ Geoscience College, Geography Department, Federal University of Minas Gerais, 31270-901, Pampulha – Belo Horizonte, Minas Gerais, Brazil

²GIS Laboratory, Architecture College, Urban Planning Department, Federal University of Minas Gerais, Federal University of Minas Gerais, 30130-140, Savassi – Belo Horizonte, Minas Gerais, Brazil

*Corresponding author: E-mail: grazielleac@ufmg.br, Tel +55 31 3409-8827

Resumo

Modelos que avaliam as mudanças na paisagem são fundamentais para o planejamento urbano. Os Modelos de Simulação permitem a elaboração de diferentes cenários de planejamento, dando suporte à avaliação de projetos previstos através de um conjunto de métricas e regras. O uso de cenários para a projeção e simulação de cenários futuros não é novo nas geociências nem mesmo na área de planejamento, no entanto, em muitos países em desenvolvimento, como o Brasil, essa metodologia é pouco utilizada. O objetivo neste artigo é a comparação entre os métodos Análise Fatorial, Crámer Von-Mises, Monte Carlo e Regressão Logística para a seleção de variáveis explicativas que compõem o modelo de mudanças da paisagem urbana na Pampulha – Minas Gerais. Como resultado apresentamos a síntese das estatísticas dos diferentes métodos de seleção de variáveis assim como os parâmetros de análise do modelo de mudança. Como contribuição, o artigo apresenta e discute a escolha dos métodos indicando o mais aconselhado no processo de seleção das variáveis explicativas que compõem o Modelo de Simulação da paisagem urbana.

Palavras Chaves: Análise Fatorial, Regressão Logística, Monte Carlo, Cramér-von Mises; Modelo de Mudança

1. INTRODUÇÃO

Segundo o Geographical Sciences Committee (2014), os Modelos de Simulação são em geral construídos para testar teorias e conceitos de alterações na paisagem associadas com as dinâmicas humanas e ambientais e para explorar as implicações dessas dinâmicas em projeções futuras baseadas nas observações do mundo real. Uma das etapas mais importantes no processo de construção destes modelos é a definição das variáveis explicativas do fenômeno de estudo. Para auxiliar este processo, a análise multivariada apresenta-se como uma das alternativas possíveis.

Segundo Hair, J. F., et al (2009), análise multivariada se refere a todas as técnicas estatísticas que simultaneamente analisam múltiplas medidas sobre indivíduos ou objetos sob investigação. Assim, pode ser considerada como multivariada qualquer análise simultânea de mais do que duas variáveis, desde que estas sejam aleatórias e inter-relacionadas de tal

maneira que seus diferentes efeitos não possam ser significativamente interpretados em separado.

Neste artigo, o objetivo é a comparação dos seguintes métodos de análise multivariada como auxílio para seleção de variáveis explicativas do modelo de mudanças da paisagem urbana na Pampulha – Minas Gerais: Análise Fatorial, Cramér-von Mises, Monte Carlo e Regressão Logística.

2. MATERIAS E MÉTODOS

As bases cartográficas utilizadas neste artigo, inicialmente selecionadas de acordo com a disponibilidade dos dados e entre estes de acordo com a indicação de especialistas, apresentam as seguintes padronizações de formato, escala e sistema de referência cartográfica:

- Todas as camadas apresentam a mesma resolução espacial (pixel 20 x 20 metros);
- Todas as camadas apresentam o sistema de projeção cartográfica - WGS 84/Fuso 23S;
- Todas as camadas apresentam o mesmo retângulo envolvente, número de linhas e colunas na matriz;
- Todas as camadas foram convertidos para o formato de número (FLOAT) e configuram-se como variável numérica contínua;
- Todos os dados foram normalizados na escala de 0 a 1, onde 1 refere-se ao maior potencial de mudança e zero menor potencial, de acordo com a fórmula apresentada em Moura, et al. (2014):

$$\text{Novo valor normalizado} = [(\text{valor antigo} - \text{valor mínimo antigo}) * (\text{maior valor nova escala} - \text{menor valor nova escala})] / (\text{valor máximo antigo} - \text{valor mínimo antigo})$$

Equação 1

As bases cartográficas disponibilizadas pela Prefeitura de Belo Horizonte para este estudo foram:

Tabela 1: Relação das bases cartográficas utilizadas no artigo

Layer	Fonte
Potencial de transformação por distância das Operações Urbana	Shapefile das Operações Urbanas cedida pela PBH
Potencial de transformação por lote	Shapefile de Lotes da Pampulha: atributos referentes ao Coeficiente de aproveitamento por lote, cedida pela PBH
Densidade de Comércio	Shapefile de Postes da Cemig: atributo informando o uso dado à energia elétrica
Potencial de transformação do Zoneamento	Shapefile do Zoneamento Urbanístico, cedida pela PBH
Acessibilidade e Capilaridade	Shapefile das Tipologias de vias, cedida pela PBH
Densidade de projetos aprovados na PBH	Shapefile dos projetos aprovados na PBH, cedida pela PBH
Potencial de transformação da Vegetação Densa	Matriz de probabilidade de Mudança por Cadeia de Markov calculada a partir dos mapas de cobertura do solo de 2009 e 2011 – Fonte – Imagens RapidEye, IEF e Lab de Geoprocessamento da EA
Potencial de transformação da Vegetação Rasteira	Matriz de probabilidade de Mudança por Cadeia de Markov calculada a partir dos mapas de cobertura do solo de 2009 e 2011 – Fonte – Imagens RapidEye, IEF e Lab de Geoprocessamento da EA

2.1 – Organização e padronização das bases cartográficas

O mapa de Acessibilidade e Capilaridade (Figura 1a) foi construído a partir da base cartográfica, formato vetorial, de trechos de vias na Pampulha. Com o uso do atributo de tipo de via, foi atribuído um índice de capacidade de recebimento de fluxo da via, hierarquizado de 0 a 10. Com o emprego da função de Densidade de Kernel, foi gerada a distribuição da capilaridade e da acessibilidade, considerando como fator de capilaridade a concentração de unidades de vias, e como fator de acessibilidade a capacidade de escoamento ou fluxo segundo a tipologia de via (Moura et.al., 2011).

Tabela 2: Índice de acessibilidade e capilaridade por tipologias de vias

Tipologia de Via na Pampulha	Índice de Acessibilidade e Capilaridade
Rodovia	10
Avenida	08
Travessa, alameda, praça	05
Rua	03
Beco	01

O mapa de Densidade de projetos aprovados foi elaborado á partir da base de pontos dos projetos aprovados na Prefeitura de Belo Horizonte, no período compreendido entre 2010 e 2014. A este dado foi aplicado o *Kernel Density (Spatial Analyst, Density)* ponderado pelo número de projetos aprovados e raio de busca de 1000 metros (Figura 1b).

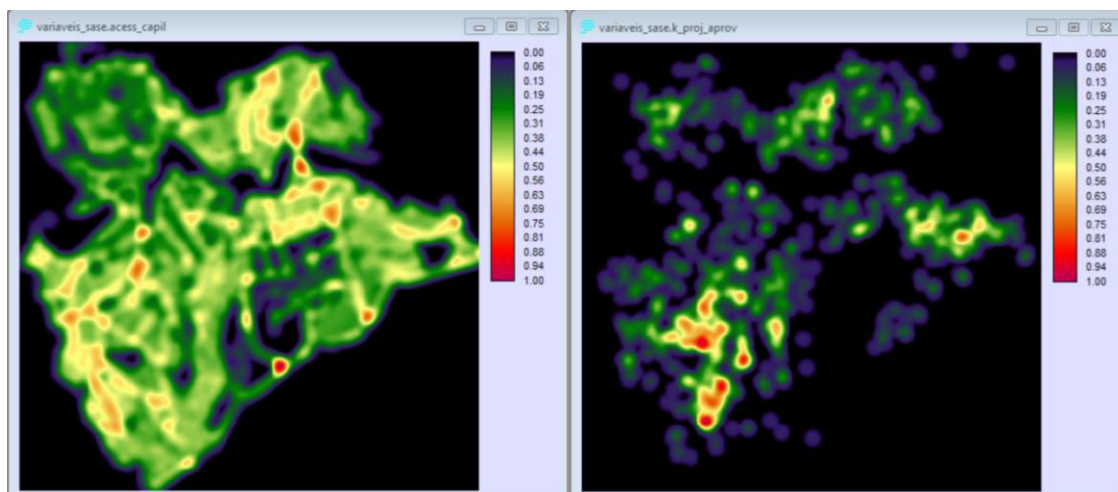


Figura 1: Variáveis explicativas, sendo: (1a) Acessibilidade e Capilaridade; (1b) Densidade de projetos aprovados na PBH

O mapa de Potencial pelo Zoneamento foi elaborado considerando o índice de permissividade em função do zoneamento, com variação na escala de 0 (zero) a 10 (dez), de modo que quanto maior o índice de permissividade, maior o potencial de mudança (Figura 2a). Os zoneamentos encontrados e seus respectivos índices de permissividades estão expressos na tabela a seguir:

Tabela 3: Índice de permissividade por zoneamento

Zoneamento	Índice de Permissividade
ZE são as regiões ocupadas ou destinadas a usos de especial relevância na estrutura urbana, nas quais é vedado o uso residencial.	0
ZPAM: São as regiões que, por suas características e pela tipicidade da vegetação, destinam-se à preservação e à recuperação de ecossistemas. É vedada a ocupação do solo nas ZPAMs, exceto por edificações destinadas exclusivamente ao seu serviço de apoio e manutenção;	
ZP-1: regiões predominantemente desocupadas, de proteção ambiental e preservação do patrimônio histórico, cultural, arqueológico ou paisagístico ou em que haja risco geológico, nas quais a ocupação é permitida mediante condições especiais;	1
ZP-2: regiões predominantemente ocupadas, de proteção ambiental, histórica, cultural, arqueológica ou paisagística ou em que existam condições topográficas ou geológicas desfavoráveis, onde devem ser mantidos baixos índices de densidade demográfica;	2
ZAR 1 - Zona de Adensamento Restrito 1 - regiões com articulação viária precária ou saturada, em que se faz necessário manter baixa densidade demográfica;	3
ZEIS-1 e ZEIS - 3: Zona de Especial Interesse Social são as regiões edificadas (ZEIS - 3) em que o Executivo tenha implantado conjuntos habitacionais de interesse social ou que tenham sido ocupadas de forma espontânea (ZEIS - 1). Há interesse público em ordenar a ocupação por meio de implantação de programas habitacionais de urbanização e regularização fundiária, urbanística e jurídica.	
ZAR -2: Zona de Adensamento Restrito 2 - regiões em que as condições de	
	4

infraestrutura e as topográficas ou de articulação viária exigem a restrição da ocupação;	
ZAP – Zona de adensamento Preferencial: São ZAP as regiões passíveis de adensamento, em decorrência de condições favoráveis de infraestrutura e de topografia	10

Fonte: Lei 7166/96 – Lei de Uso e parcelamento do Solo de Belo Horizonte

O mapa de potencial pela área construída no lote, ainda em *shapefile*, considerou potencial de valor 10 (dez) para lotes vagos, valor 5 (cinco) para lotes ocupados com edificações de apenas um andar e 0 (zero) para as demais situações. Em seguida, o dado foi convertido pra *raster*, normalizado (Figura 2b).

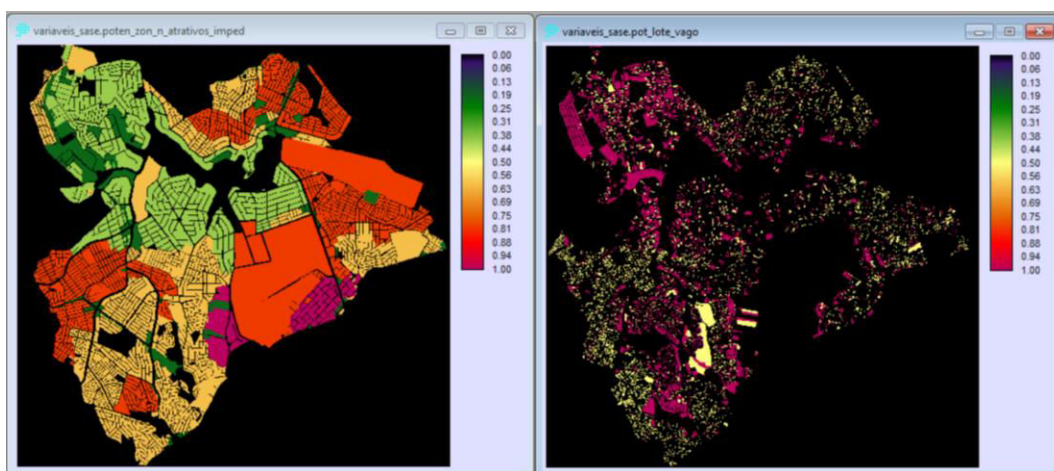


Figura 2: Variáveis explicativas, sendo: (2a) Índice de permissividade em função do zoneamento; (2b) Potencial pela área construída no lote

Também foi adotada como variável explicativa o mapa de Potencial de Transformação em Função das Operações Urbanas (figura 3a), pois considera-se que quanto mais próximo da área que sofrerá intervenções das operações urbanas, maior o potencial de transformação.

Segundo o Art. 65 da Lei nº 9959/2010, entende-se por Operação Urbana “o conjunto de intervenções e medidas coordenadas pelo Poder Executivo Municipal, com a participação de agentes públicos ou privados, com o objetivo de viabilizar projetos urbanos de interesse público, podendo ocorrer em qualquer área do Município” (Belo Horizonte, 2010). Neste caso, foram consideradas as operações urbanas programadas ou já em curso na regional Pampulha.

O mapa de Densidade de Comércio foi elaborado a partir da base de pontos dos postes da CEMIG (projeto Gemini). Considerou-se apenas os postes que apresentavam mais de 5 ligações associadas à atividade comercial. A este dado foi aplicado o *Kernel Density (Spatial Analyst, Density)* ponderado pelo número de atividades comerciais e raio de busca de 1000

metros (Figura 3b).




Figura 3: Variáveis explicativas, sendo: (3a) Distância das Operações Urbanas; (b) Densidade de Comércio – mais de 05 centros comerciais por ponto

O interesse maior da investigação é avaliar o comportamento e as mudanças que sofrerá a tipologia “Uso Urbano” do mapa de “Cobertura do Solo”, mas é também necessária a inclusão de variáveis explicativas que respondam pelas outras tipologias de cobertura do solo, quais sejam: cobertura vegetal densa e cobertura por vegetação rasteira. Desta forma, acrescentou-se na lista de possíveis variáveis explicativas as variáveis de probabilidade condicional de mudança que respondem pelas tipologias de vegetação densa (Figura 4a) e rasteira (Figura 4b) elaboradas pelo método de Cadeia de *Markov*, e o Mapa de potencial de mudanças das tipologias de cobertura do solo (figura 4c) considerando as mudanças verificadas no período compreendido entre 2009 e 2013, através do método de máxima verossimilhança. Todos os dados foram trabalhados nos softwares Arcgis 10x e Idrisi/Selva.

Embora o interesse maior seja avaliar o comportamento e as mudanças que sofrerá a tipologia de cobertura do solo Urbano, faz-se necessário a inclusão de variáveis explicativas que também respondam pelas outras tipologias de cobertura do solo presentes no mapa que servirá de referência para o mapa projetado. Desta forma, acrescentou-se na lista de possíveis variáveis explicativas as variáveis de probabilidade condicional de mudança que responde pelas tipologias de vegetação densa (figura 4a) e rasteira (figura 4b) elaboradas pelo método de Cadeia de *Markov*. Todos os dados foram trabalhados nos softwares Arcgis 10x e Idrisi/Selva.

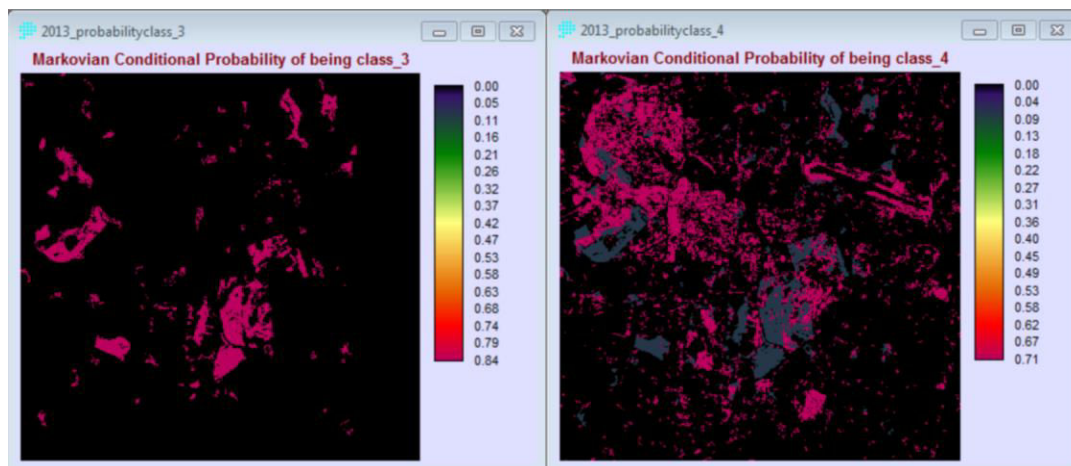


Figura 4: Probabilidade condicional de mudança – (4a) Veg. Densa; (4b) Veg. Rasteira;

2.2 Métodos

São apresentados a descrição geral e os parâmetros que consistem em cada um dos métodos aqui comparados.

2.2.1 - Análise Fatorial na seleção de variáveis

A Análise Fatorial é uma técnica de interdependência cujo propósito principal é definir a estrutura inerente entre as variáveis na análise. Na Análise Fatorial as variáveis não são divididas em conjuntos dependentes e independentes, pelo contrário, todas as variáveis são analisadas como um único conjunto (HAIR, J. F., et al., 2009). Esta técnica tem sido usada nas mais diversas áreas do conhecimento, como por exemplo, em Ciências Sociais (KIM, J.O., 1975), Biologia (FOWLER, 1993), na Geografia Urbana e planejamento (MENEZES et al., 1978; SIMOES, R.F., 2005), entre outros.

Segundo Johnson & Wichern (1988), considerando um conjunto de “p” variáveis, com “n” observações para cada variável, obtém-se o seguinte arranjo de valores, a partir do conjunto de dados (Tabela 04):

$$[x_{ij}], \quad i = 1, 2, \dots, n, \quad j = 1, 2, \dots, p$$

Equação 2

Tabela 4: Exemplo de conjunto de dados de uma análise fatorial

Indivíduos	Variáveis			
	X_1	X_2	...	X_p
1	x_{11}	x_{12}	...	x_{1p}
2	x_{21}	x_{22}	...	x_{2p}
...
n	x_{n1}	x_{n2}	...	x_{np}

O modelo da análise de fatores supõe que cada variável X_j é linearmente dependente de poucas variáveis aleatórias não observadas F_1, F_2, \dots, F_m ($m < p$) chamadas fatores comuns, e p fontes adicionais de variação e_1, e_2, \dots, e_p , chamadas erros ou, algumas vezes, fatores específicos (JOHNSON & WICHERN, 1988).

Em particular, o modelo da análise de fatores pode ser escrito como:

$$\begin{aligned} X_1 &= a_{11}F_1 + a_{12}F_2 + \dots + a_{1m}F_m + e_1 \\ X_2 &= a_{21}F_1 + a_{22}F_2 + \dots + a_{2m}F_m + e_2 \\ &\dots \\ X_p &= a_{p1}F_1 + a_{p2}F_2 + \dots + a_{pm}F_m + e_p \end{aligned}$$

ou seja,

$$X_j = a_{j1}F_1 + a_{j2}F_2 + \dots + a_{jm}F_m + e_j,$$

Equação 3

onde X_j é a j -ésima variável, $a_{j1}, a_{j2}, \dots, a_{jm}$ são as cargas dos fatores para a j -ésima variável e F_1, F_2, \dots, F_m são m fatores comuns não correlacionados, com “ m ” menor que “ p ”.

Os p valores observados X_p são expressos em termos de $p + m$ variáveis aleatórias não observáveis ($F_1, F_2, \dots, F_m; \varepsilon_1, \varepsilon_2, \dots, \varepsilon_p$).

Neste artigo, a análise fatorial foi aplicada através do software STATA/MP 12.1, no qual considerou como fator de exclusão da variável explicativa do Modelo de Simulação da paisagem urbana da Pampulha aquelas que apresentaram UNIQUENESS > 0.6 tanto para o teste geral, quanto para cada variável individual. Tais variáveis foram omitidas da análise fatorial uma por vez, sendo aquela com maior valor eliminada a cada vez (MINGOTI, 2005) Os resultados da análise podem ser verificados na tabela 5.

2.2.2 - Cramér-von Mises na seleção de variáveis

O método de *Crámer-von Mises* foi proposto em 1946 pelo pesquisador que deu nome ao método. Tem como objetivo mensurar em uma escala de 0 a 1 a associação ou dependência entre variáveis (ANDERSON, 1962; DARLING, 1954; STEPHENS, 1970). O índice pode ser obtido pela seguinte equação, segundo Liebertau (1983):

$$v = \frac{\sqrt{\chi^2}}{\sqrt{n(q-1)}}$$

Equação 4

Onde:

χ^2 - É o coeficiente Chi-quadrado $((O - E)^2/2)$

O é a frequência observada para uma categoria;

E é a frequência esperada na categoria correspondente;

n é o tamanho da amostra;

q é o menor valor das linhas e colunas da imagem da cobertura do solo.

Eastman (2012) nos diz que a interpretação do valor de Crámer's V se dá da seguinte maneira:

A high Cramer's V indicates that the potential explanatory value of the variable is good, but does not guarantee a strong performance since it cannot account for the mathematical requirements of the modeling approach used and the complexity of the relationship. However, it is a good indication that a variable can be discarded if the Cramer's V is low In general, we have found the variables that have a Cramer's V of about 0.15 or higher are useful while those with values of 0.4 or higher are good. (EASTMAN, 2012).

Desta forma, aconselha-se retirar a variável do modelo quando esta atingir valores menores de 0.15.

Neste artigo foi usado o módulo "*Test and Selection of Site and Driver Variables* – disponível no *Land Change Modeler – IDRISI SELVA*" para o teste Crámer's V. O resultado do potencial exploratório das variáveis explicativas no Modelo de Simulação proposto pode ser verificado na tabela 05.

2.2.3 – Monte Carlo na seleção de variáveis

O método de Monte Carlo pode ser usado para avaliar o grau de incerteza presente na metodologia ou no modelo construído. Este avalia a sensibilidade espacial dos dados e lida com a incerteza no processo de análise multicritério (Moura, et al. 2014). Como nos fala Ligmann-Zielinska, et al. (2012, 2014), “*models should be thoroughly evaluated to ensure their robustness under a wide range of possible conditions, where robustness is defined as a minimal response of model outcome to changing inputs*”.

O processo consiste em aplicar a análise de Monte Carlo para simular possíveis pesos para as variáveis, dentro de limites de máximo e mínimo em uma faixa de valores. Foi utilizada a ferramenta “*Monte Carlo Weighted Sum*”, desenvolvida por Jankowski e Ligmann-Zielinska (2012, 2014), no pacote “*Multicriteria Evaluation for Discrete Set of Options*”, no item “*Uncertainty and Sensitivity Analysis*”, considerando como estrada de dados todas as variáveis disponibilizadas para compor o modelo de mudança. No estudo de caso foi atribuído as todas as variáveis a mesma margem de variação dos pesos mínimos e máximos (mínimo de 0.07 e máximo de 0.17).

Esta primeira análise simula diferentes pesos para as variáveis dentro do limite estabelecido e apresenta como resultado uma análise de multicritérios em uma das colunas (AVG – average), destacando segundo um range ou arranjo hierárquico que indica as ocorrências mais importantes no resultado do potencial analisado, tanto na resposta de “range AVG”, como na resposta de “score AVG”. Se a análise era o potencial de crescimento e transformação urbana, o range ordena segundo as ocorrências mais significativas para que aconteça a transformação. Além desta análise de multicritérios segundo a ordem de importância, o processo apresenta o nível de incerteza, na forma de “score STD”, o que significa que cada ocorrência territorial é hierarquizada segundo o nível de incerteza resultante da combinação de variáveis naquela posição.

Segundo Moura, et al. (2014) e Jankowski, Ligmann-Zielinska (2012, 2014) os resultados podem ser interpretados da seguinte maneira:

1. *Alta posição no rank da média e baixa posição no rank do desvio padrão - significa a posição vencedora e com alta confiabilidade; logo a opção pode ser mantida*
2. *Alta posição no rank da média e alta posição no rank do desvio padrão - significa a posição de maior incerteza, exigindo estudos mais detalhados em função da instabilidade.*

3. *Baixa posição no rank da média e baixa posição no rank do desvio padrão - representam a posição perdedora e com alta confiabilidade, logo a opção pode ser descartada.*
4. *Baixa posição no rank da média e alta posição no rank do desvio padrão - significa posição perdedora que pode ser eliminada, mas com menos confiança sobre a decisão do que o caso 3.*

Além do aplicativo de "*Uncertainty and Sensitivity Analysis*", é utilizado também o aplicativo de "*Variance-Based Global Sensitivity Analysis*", através do "*Variance Decomposition*", cujo objetivo é avaliar o quanto cada variável envolvida contribuiu para o nível de incerteza individualmente, e o quanto ela interage com as demais variáveis. O objetivo é definir qualitativamente as variáveis que tiveram mais influência sobre o resultado da análise de multicritérios, através de dois índices: o nível de sensibilidade de primeira ordem (S) e o efeito total do índice de sensibilidade (ST). O resultado é o "Average Shift in Ranks" e o "Robust Winner". Segundo Jankowski, Ligmann-Zielinska (2012), quanto maior a incerteza, maior a possibilidade de retirar a variável do modelo. Os índices são:

- S – corresponde ao valor da incerteza do dado. Varia na escala de 0 a 1, onde zero é menor incerteza e 1 maior incerteza. Possíveis pequenos valores negativos podem ser erros de arredondamento do processo e devem ser considerados como se fossem zero. Os maiores valores significam o maior impacto no ranking e a maior variabilidade.
- ST – índice de interação de cada variável com as demais.
- %S – Refere-se ao percentual da incerteza de cada variável. A soma destes valores deve ser 100%. Caso a soma não dê 100%, o valor faltante refere-se ao índice de NONL, que demonstra o percentual geral de interação entre variáveis na composição do modelo.
- % ST - Refere-se ao percentual individual de interação de cada variável com as demais. A soma destes valores devem ser 100%.

O resultado do grau de incerteza das variáveis explicativas no Modelo de Simulação proposto pela técnica de SASE ("*Sensitivity Analysis to Suitability Evaluation*"), baseada na simulação de Monte Carlo e a partir da "*Variance Decomposition*" pode ser verificado na tabela 05.

2.2.4 – Regressão Logística na seleção de variáveis

No caso de Modelos de Simulação da paisagem urbana, como a variável dependente refere-se a uma variável categórica/qualitativa, o modelo de regressão linear não pode ser aplicado, aconselhando-se portanto o método de regressão logística.

A regressão logística é binomial, ou seja, a variável dependente de entrada deve ser de natureza binária e pode ter apenas dois valores possíveis (0 ou 1). Tal análise de regressão é geralmente empregada para estimar um modelo que descreve a relação entre uma ou mais variáveis contínuas independentes para a variável dependente binária, geralmente de caráter nominal ou qualitativo (FIGUEIRA, 2006; PETERNELLI, 200-; EASTMAN, 2012).

Quando o modelo usa uma variável independente para explicar o processo de mudança trata-se de modelo de Regressão logística simples, se usa mais de uma variável independente, Regressão logística múltipla. O pressuposto básico é que se a variável dependente assumir o valor 1 (resposta positiva), então esta segue a curva logística e seu valor pode ser estimado com a seguinte fórmula:

$$P (y=1|X) = \frac{\exp (\Sigma BX)}{1 + \exp (\Sigma BX)}$$

Equação 5

Onde:

P é a probabilidade da variável dependente ser 1;

X é a variável independente,

$X = (x_0, x_1, x_2, \dots, x_k)$, $X_0 = 1$

B é o parâmetro de estimativa;

$B = (b_0, b_1, b_2, \dots, b_k)$,

São alguns princípios do modelo de regressão logística, segundo EASTMAN, (2012):

The dependent random variable, Y, is assumed to be binary, taking on only two values (0 and 1); the outcomes on Y are assumed to be mutually exclusive and exhaustive; Y is assumed to depend on K observable variables Xk and the relationship is non-linear and follows the logistic curve; the data are generated from a random sample of size N, with a sample point denoted by i, i = 1, ..., N; no restriction on the independent variables except that they can not be linearly related (implies that N>K); the error term of each observation is assumed to be independent of the error terms of all other observations (EASTMAN, 2012)

A análise dos resultados da Regressão logística se dá através do teste de significância de

Ronald Fisher (1925): "*when such tests are available we may discover whether a second sample is or is not significantly different from the first.*"

O teste de significância (*Goodness of Fitting*) de Fisher (1925) considera um alfa (α) de 5%, ou seja, esta é a probabilidade de se rejeitar a hipótese nula quando ela é efetivamente verdadeira ou de se rejeitar a hipótese alternativa quando ela é efetivamente verdadeira. Para tal é avaliado o *p-value*, já que este fornece um índice de quanto os dados contradizem a hipótese nula. Além disso, ele permite que diferentes experimentadores utilizem seus respectivos níveis de significância para avaliar os resultados do teste de hipóteses. Na regressão logística, retira-se a variável do modelo quando o *p-value* for maior que 0,05. O resultado do *p-value* das variáveis explicativas no Modelo de Simulação proposto pela regressão logística pode ser verificado na tabela 05.

2.3 Land Change Modeler (LCM) for Ecological Sustainability – um Modelo de Simulação da paisagem para sustentabilidade ecológica

Para definir as regras de transição do modelo, as variáveis explicativas foram avaliadas por Redes Neurais através da ferramenta *Multi-Layer Perceptron (MLP)* disponível no aplicativo *Land Change Model (LCM)* do *Idrisi/Selva*, que utiliza da Cadeia de Markov para a espacialização das mudanças.

De uma forma geral, podemos afirmar que as Redes Neurais Artificiais buscam identificar e reprojeter as conexões existentes entre as camadas de informação a serem avaliadas e que este aprendizado por rede é usado para definir as regras de transição para então se projetar o cenário futuro. (ATKINSON e TATNALL, 1997; BRAGA et al., 2000; CHAN et al., 2001; CIVCO, 1993; HSIEH, 2009; KARUL e SOYUPAK, 2003; GENARO et al., 2010; GEOGRAPHICAL SCIENCES COMMITTEE, 2014). Desta forma, o *MLP* gera associações prévias de classe para cada um dos *pixels* (posição na matriz ou célula) de validação em cada iteração e relata a precisão global, bem como uma pontuação por potencial de transformação.

A pontuação por potencial de transformação representa a diferença entre a precisão calculada utilizando os dados de validação e a precisão esperada, se fosse para obter o valor de forma aleatória nas associações das classes dos *pixels* validados (EASTMAN, 2012). Como resultado das análises, é apresentada a “Acurácia do Modelo”, ou seja, o desempenho do modelo considerando a influência de cada variável e a ordem de importância das variáveis explicativas.

Para a espacialização das mudanças, utiliza-se a Matriz de Probabilidade de Mudanças elaborada por Cadeia de Markov, a qual expressa a probabilidade total (em percentual) do pixel de mudar para outra classe ou permanecer na mesma no tempo futuro. As mudanças verificadas são resultado da interação entre as regras de transição elaboradas por Redes Neurais e a Matriz de Probabilidade de Mudanças.

O *Land Change Modeler (LCM) for Ecological Sustainability* é um aplicativo comercial desenvolvido pela *Clark Labs* e tem como objetivo a projeção de cenários futuros e a avaliação de impactos de cunho ecológico. Foi desenvolvido inicialmente para aplicações na Ecologia, entretanto tem sido amplamente utilizado para a modelagem de mudanças de uso do solo em geral.

3. RESULTADOS E DISCUSSÃO:

Como resultado são apresentadas as tabelas 05 a 07, que registram as estatísticas dos diferentes métodos analisados, a síntese dos parâmetros de classificação, a aplicação dos parâmetros na seleção das variáveis e o desempenho do Modelo de Simulação por método de seleção de variáveis.

Tabela 5: Síntese comparativa entre as variáveis explicativas considerando diferentes métodos estatísticos

Variável	Análise fatorial		Cramér-von Mises	Monte Carlo				Regressão Logística Binomial
	<i>Uniqueness</i>			<i>Crámer' V</i>	<i>S</i>	<i>ST</i>	<i>%S</i>	<i>%ST</i>
Potencial de transformação por distância das Operações Urbanas	0.3893	0.3730	0.1632	0.139	0.814	13.9	21.0	0.000
Potencial de transformação por lote	0.6265	Retirada na 2ª rodada	0.1100	0.025	0.268	2.5	6.9	0.000
Densidade de Comércio	0.3244	0.3131	0.2844	0.012	0.907	1.2	23.4	0.000
Potencial de transformação do Zoneamento	0.4958	0.4892	0.2048	0.03	0.547	3.0	14.1	0.000
Acessibilidade e Capilaridade	0.2804	0.2613	0.2308	0.09	0.31	9.0	8.0	0.004
Densidade de projetos aprovados na PBH	0.3477	0.3424	0.0864	0.052	0.17	5.2	4.4	0.000

Potencial de transformação da Veg. Densa	0.2703	0.1173	0.5774	0.024	0.283	2.4	7.3	0.000
Potencial de transformação da Veg. Rasteira	0.3028	0.3317	0.8165	-0.012	0.582	-1.2	15.0	0.000

3.1 Parâmetros de análise dos dados

Para realizar a análise comparativa dos resultados, apresenta-se os seguintes parâmetros de classificação dos dados:

Tabela 6: Síntese dos parâmetros de classificação dos resultados

MÉTODO	MANTER	RETIRAR	FONTE
Cramér-von Mises	Coeficiente de Cramer igual ou maior que 0.15	Menor que 0.15	Eastman, 2012.
Análise fatorial	Uniqueness igual ou menor que 0.6 ou Esfericidade de Bartlet (significância <0.05) ou Medidas de valores de adequação da amostra (MSA) <0.5	Uniqueness maior que 0.6; ou Esfericidade de Bartlet (significância > 0.05); ou Medidas de valores de adequação da amostra (MSA) > 0.5	Mingoti, 2005; Hair, J.F., et al., 2009.
Regressão Logística Binomial	Alfa (significância) maior ou igual a 95% ou <i>p-value</i> menor ou igual a 0,05	Alfa (significância) menor que 95% ou <i>p-value</i> maior que 0,05	R. A. Fisher, 1925.
Monte Carlo	Mantem as variáveis de menor valor S (pouca ou nenhuma incerteza da importância da variável no modelo) e baixo ST (sua retirada afeta o conjunto)	Retira as variáveis de maior incerteza e maior ST (alta interação com as demais, pois sua retirada não afetará a resposta do conjunto)	Jankowski & Ligmann-Zielinska, 2012.

Baseado nos parâmetros propostos, temos os seguintes resultados:

Tabela 7: Aplicação dos parâmetros de análise estatística Monte Carlo, Regressão Linear e Cramér-von Mises na seleção de variáveis explicativas

Variáveis	Análise Fatorial	Cramér-von Mises	Monte Carlo	Regressão Logística
Potencial de transformação por distância das Operações Urbana	MANTER	MANTER	MANTER	MANTER
Potencial de transformação por lote	RETIRAR	RETIRAR	MANTER	MANTER
Densidade de Comércio	MANTER	MANTER	MANTER	MANTER

Pot. Transformação do Zoneamento	MANTER	MANTER	MANTER	MANTER
Acessibilidade e Capilaridade	MANTER	MANTER	MANTER	MANTER
Densidade de projetos aprovados na PBH	MANTER	RETIRAR	MANTER	MANTER
Pot. Transformação da Veg. Densa	MANTER	MANTER	MANTER	MANTER
Pot. Transformação Veg. Rasteira	MANTER	MANTER	MANTER	MANTER

No LCM, todos os modelos rodaram com o mesmo Momentum factor, Sigmoid constant, Acceptable RMS e Iterations. No módulo Validate do IDRISI/Selva, calculou os índices de validação⁵, também apresentados na tabela 8:

Tabela 8: Desempenho do Modelo de Simulação na comparação dos métodos de análise estatística Monte Carlo, Regressão Linear e Cramér-von Mises

Parâmetros	Análise fatorial	Crámer von Mises	Monte Carlo	Regressão Logística
Tipologias de Cobertura do solo	4	4	4	2
Input layer neurons	7	6	8	8
Hidden layer neurons	8	8	9	4
Output layer neurons	8	8	8	2
Requested samples per class	444	444	444	10000
Final learning rate	0.001	0.001	0.0005	0.0005
Momentum factor	0.5	0.5	0.5	0.5
Sigmoid constant	1	1	1	1
Acceptable RMS	0.01	0.01	0.01	0.01
Iterations	10000	10000	10000	10000
Training RMS	0.171	0.1669	0.1795	0.1543
Testing RMS	0.1861	0.1994	0.187	0.1539
Accuracy rate	81.18%	79.14%	80.63%	96.55%
Skill measure	0.7849	0.7616	0.7786	0.9311

⁵ [1] Kappa for no information (denoted K_{no}), [2] Kappa for grid-cell level location (denoted K_{location}), and [3] Kappa for stratum-level location (denoted K_{locationStrata}). All of these statistics are linear functions of points in the VALIDATE output. Specifically, $K_{no} = \{M(\mathbf{m})-N(\mathbf{n})\}/\{P(\mathbf{p})-N(\mathbf{n})\}$. $K_{location} = \{M(\mathbf{m})-N(\mathbf{m})\}/\{P(\mathbf{m})-N(\mathbf{m})\}$. $K_{locationStrata} = \{M(\mathbf{m})-H(\mathbf{m})\}/\{K(\mathbf{m})-H(\mathbf{m})\}$. K_{location} indicates how well the grid cells are located on the landscape. K_{locationStrata} indicates how well the grid cells are located within the strata (Eastman, 2012).

VALIDATE = K_Standart	0.8501	0.83	0.8327	0.8257
VALIDATE = K_no	0.9319	0.9227	0.9239	0.8888
VALIDATE = K_Location	0.9608	0.938	0.941	0.9491
VALIDATE = K_LocationStrata	0.9608	0.938	0.941	0.9491

A tabela 8 demonstra que não há consenso entre os métodos sobre a necessidade de se retirar alguma das variáveis inicialmente disponíveis para a análise. Dentre todas as variáveis analisadas, a indicada como a mais propensa a ser retirada do modelo, pelos métodos de Análise Fatorial e de Cramér-von Mises, foi a de Potencial de Transformação por lote. Isto demonstra que esta variável exerce baixa influência na predição da cobertura do solo, uma vez que as transformações nesta escala se dão de acordo com o interesse do proprietário, resultando em mudanças mais lentas.

As variáveis Potencial de Transformação do Zoneamento, Potencial de Transformação por Distância das Operações Urbana, Potencial de Transformação por Distância dos Pontos de Densidade de Comércio, Acessibilidade e Capilaridade, Potencial de Transformação da Vegetação Densa e Potencial de Transformação da Vegetação Rasteira mostraram-se como variáveis estruturadoras da paisagem urbana na Pampulha, com elevado índice de resposta às transformações nesta paisagem.

Embora todos os métodos tenham apresentado índices de validação do Modelo de Simulação aceitáveis (acima de 90% de acerto na predição da cobertura do solo futura), o método de Regressão Logística mostrou uma taxa de aprendizado por redes neurais melhor do que os demais métodos, entretanto cabe ressaltar que isto se deu por neste modelo ter apenas duas categorias de cobertura do solo (urbano e não-urbano), enquanto os demais modelos apresentam quatro categorias (água, antrópico, vegetação densa e rasteira), sendo modelos mais complexos.

Dos modelos que apresentaram quatro tipologias de cobertura do solo o que obteve melhor índice de acurácia, ou seja, melhor taxa de aprendizado por redes neurais, foi a Análise Fatorial (81.18%), seguida de Monte Carlo (80.63%) e Cramér-von Mises (79.14%).

No que se refere à validação do Modelo de Simulação da paisagem urbana da Pampulha, os melhores índices foram apresentados por Análise Fatorial, seguida de Monte Carlo e Cramér-

von Mises. Sobre o K_location, a Regressão logística apresenta índices melhores que o Cramér-von Mises, entretanto os índices da regressão logística refere-se a um mapa de cobertura do solo menos complexo que o analisado pelo Cramér-von Mises.

5. CONSIDERAÇÕES FINAIS

O Modelo de Simulação da paisagem mostra-se como um importante instrumento de planejamento urbano. Entretanto, para a sua correta aplicação, ele precisa que alguns pré-requisitos sejam atendidos, tais como um bom mapa de cobertura/uso do solo que represente o comportamento do objeto de estudo em diferentes períodos, e que as variáveis explicativas consigam identificar as regras de transição das mudanças verificadas na paisagem no intervalo de tempo analisado.

Uma das etapas de maior investimento de tempo e recursos humano e financeiro é a de calibração do modelo de mudança, o qual consiste em identificar quais as variáveis explicativas que respondem de forma satisfatória pelas regras de transição. Neste artigo, o propósito de comparar métodos de análise multivariada para a seleção das variáveis explicativas vem com o intuito de ajudar a tornar mais eficiente esta importante tarefa.

Os métodos de Análise Fatorial, Cramér-von Mises, Monte Carlo e Regressão Logística foram os selecionados por serem amplamente conhecidos por pesquisadores de diferentes áreas, mas ainda pouco aplicados com este objetivo. Desta forma, pode-se verificar que a aplicação das técnicas de análise multivariada se mostrou extremamente eficaz para a análise urbana, uma vez que o objeto de estudo é complexo e necessita de mais de duas variáveis para explicar seu comportamento. Todos os métodos apresentaram respostas satisfatórias para compor o modelo de mudança, mas destaca-se que a Análise Fatorial mostrou-se com o melhor desempenho. Como resultado, aconselha-se este método como o indicado para a seleção de variáveis para compor o Modelo de Simulação da paisagem urbana.

REFERÊNCIAS:

- ANDERSON, Theodore W. **On the distribution of the two-sample Cramer-von Mises criterion**. The Annals of Mathematical Statistics, p. 1148-1159, 1962.
- ATKINSON, Peter M.; TATNALL, A. R. L. **Introduction neural networks in remote sensing**. International Journal of remote sensing, v. 18, n. 4, p. 699-709, 1997. CHAN et al., 2001;
- BELO HORIZONTE. **Lei nº 7.165, DE 27 DE AGOSTO DE 1996**. Institui o Plano Diretor do Município de Belo Horizonte. Disponível em: <http://www.cmbh.mg.gov.br/leis/legislacao/pesquisa>
- BELO HORIZONTE. **Lei nº 9959 DE 21 DE JULHO DE 2010** – Altera as leis nº 7.165/96 - que institui o Plano Diretor do Município de Belo Horizonte - e nº 7.166/96 – que estabelece normas e condições para parcelamento, ocupação e uso do solo urbano no Município -, estabelece normas e condições para a urbanização e a regularização fundiária das Zonas de Especial Interesse Social, dispõe sobre parcelamento, ocupação e uso do solo nas Áreas de Especial Interesse Social, e dá outras providências. Diário Oficial do Município (Poder Executivo). Ano XVI • N. 3.628. Disponível em: <http://www.cmbh.mg.gov.br/leis/legislacao/pesquisa>
- BRAGA, A. de P.; CARVALHO, ACPLF; LUDERMIR, Teresa Bernarda. **Redes neurais artificiais: teoria e aplicações**. Livros Técnicos e Científicos, 2000.
- CIVCO, Daniel L. **Artificial neural networks for land-cover classification and mapping**. International Journal of Geographical Information Science, v. 7, n. 2, p. 173-186, 1993.
- CHAN, Jonathan Cheung-Wai; CHAN, Kwok-Ping; YEH, Anthony Gar-On. **Detecting the nature of change in an urban environment: A comparison of machine learning algorithms**. Photogrammetric Engineering and Remote Sensing, v. 67, n. 2, p. 213-225, 2001.
- DARLING, Donald A. **The kolmogorov-smirnov, cramer-von mises tests**. The Annals of Mathematical Statistics, p. 823-838, 1957.
- EASTMAN, J. R. **IDRISI Selva Manual**. Clark University. Sitio web: www.clarklabs.org, 2012.
- FIGUEIRA, Cleonis Viater. **Modelos de regressão logística**. Dissertação de Mestrado . Universidade Federal do Rio Grande do Sul, 2006.
- FISHER, R. A. **Statistical Methods for Research Workers**, Edinburgh: Oliver and Boyd, 1925, p.43.
- FOWLER, H. G. **A novel application of factor analysis to examine interactions of the fossorial predators *Sirthenia striata* (Hemiptera: Reduviidae) and *Megacephala fulgida* (Coleoptera: Cicindelidae)**. Rev. Mat. Estat., 11:93-103, 1993.
- GENARO, N. et al. **A neural network based model for urban noise prediction**. The Journal of the Acoustical Society of America, v. 128, n. 4, p. 1738-1746, 2010.
- GEOGRAPHICAL SCIENCES COMMITTEE et al. **Advancing Land Change Modeling: Opportunities and Research Requirements**. National Academies Press, 2014.
- HAIR, Joseph F., et al. **Análise multivariada de dados**. Bookma, 2009
- HSIEH, William W. **Machine learning methods in the environmental sciences: neural networks and kernels**. Cambridge university press, 2009.

JOHNSON, R. A. & WICHERN, D. W. **Applied multivariate statistical analysis**. Englewood Cliffs, N. J., Prentice-Hall, Inc., 1988. 607 p.

KARUL, C.; SOYUPAK, S. **A comparison between neural network based and multiple regression models for chlorophyll-a estimation**. In: Ecological Informatics. Springer Berlin Heidelberg, 2003. p. 249-263.

KIM, J.O. **Factor analysis**. In: NIEH, H.; HULL, C.H. ; JENKINS, J.C.; STENBRENNER, K.; BENJ, D.H. (eds.). *Statistical package for social sciences*. New York. Megal Hill, 1975. v 5. p 468-514.

LIEBETRAU, Albert M. (Ed.). **Measures of association**. Sage, 1983.

LIGMANN-ZIELINSKA, A., JANKOWSKI, P. **Impact of proximity-adjusted preferences on rank-order stability in geographical multicriteria decision analysis**. Journal of Geographical Systems , 14(2), 167-187. 2012.

LIGMANN-ZIELINSKA, A., JANKOWSKI, P. **Spatially-explicit integrated uncertainty and sensitivity analysis of criteria weights in multicriteria land suitability evaluation**. Environmental Modelling & Software , DOI: 0.1016/j.envsoft.2014.03.007. 2014.

MENEZES, A.C.F.; FAISSOL, S.; FERREIRA, M.L. **Análise da matriz geográfica: estruturas e inter-relações**. In: IBGE. Tendências atuais na geografia urbano-regional: teorização e quantificação. Rio de Janeiro, 1978. p. 67-109.

MINGOTI, Sueli Aparecida. **Análise de dados através de métodos de estatística multivariada: uma abordagem aplicada**. Editora UFMG, 2005.

MOURA, Ana Clara Mourão; JANKOWSKI, Piotr; COCCO, Chiara. **Contribuições aos estudos de análises de incertezas como complementação às análises multicritérios: “Sensitivity Analysis to Suitability Evaluation”**. Anais do Congresso Brasileiro de Cartografia – Gramado – RS. 2014.

PETERNELLI, Luiz Alexandre. **Regressão Linear e Correlações - Cap 09**. 200-. Acessado em 31/12/2014. Disponível em: <http://www.dpi.ufv.br/~peterneli/inf162.www.16032004/materiais/CAPITULO9.pdf>

SIMÕES, Rodrigo Ferreira. **Métodos de análise regional e urbana: diagnóstico aplicado ao planejamento**. Belo Horizonte: Cedeplar/UFMG, 2005.

STEPHENS, Michael A. **Use of the Kolmogorov-Smirnov, Cramér-Von Mises and related statistics without extensive tables**. Journal of the Royal Statistical Society. Series B (Methodological), p. 115-122, 1970.

Artigo 02: Modelo de Simulação da Paisagem Urbana da Pampulha integrando metodologias de Análise Fatorial, Análise de Multicritério e *Exogenous Quantity* no módulo Geomod/Idrisi

Modelo de Simulação da Paisagem Urbana da Pampulha integrando metodologias de Análise Fatorial, Análise de Multicritério e Exogenous Quantity no módulo Geomod/Idrisi

Carvalho, G.A.^{1,2*}, **Moura, A.C.M.**²

¹Geoscience College, Geography Department, Federal University of Minas Gerais, 31270-901, Pampulha – Belo Horizonte, Minas Gerais, Brazil

²GIS Laboratory, Architecture College, Urban Planning Department, Federal University of Minas Gerais, Federal University of Minas Gerais, 30130-140, Savassi – Belo Horizonte, Minas Gerais, Brazil

*Corresponding author: E-mail: grazielleac@ufmg.br, Tel +55 31 3409-8827

Resumo:

Os Modelos de Simulação da Paisagem são comumente usados nas Geociências. Estes são essenciais no processo de tomada de decisão e funcionam como uma ferramenta de suporte ao planejamento urbano. Este artigo tem como objetivo apresentar o Modelo de Simulação da Paisagem da Regional Pampulha baseada na metodologias “Análise Fatorial” na seleção de variáveis, Análise de multicritérios para elaborar o mapa de Potencial de mudança e *Exogenous Quantity*, presente no módulo GEOMOD do IDRISI/SELVA na projeção do mapa de cobertura do solo para o ano de 2020. Como resultado, apresentamos as variáveis selecionadas para compor o Modelo de Simulação de acordo com a Análise Fatorial, o mapa de potencial á mudança (não urbano para urbano) e a projeção da cobertura do solo. O uso do Geomod como Modelo de Simulação nos mostra uma alternativa para a modelagem uma vez que requer poucos dados iniciais. Entretanto, observa-se que o uso desta aplicação é recomendada para estudos exploratórios, uma vez que não é possível a aplicação deste em um mapeamento que apresente mais do que duas tipologias de uso ou cobertura do solo.

Palavras Chaves: Modelo de Simulação da paisagem urbana, Análise de Multicritério, Exogenous Quantity; GEOMOD

1. INTRODUÇÃO

O processo de modelagem e projeção de cenários do uso/cobertura do solo em geral une uma técnica para definir as variáveis explicativas, uma que permita identificar as regras de transição que favorecem que um tipo de uso ou cobertura se transforme em outro ou mesmo permaneça como está, e outra técnica para fazer a projeção das mudanças. Neste artigo, o objetivo é a organização de um Modelo de Simulação da paisagem urbana que integre o processo de seleção de variáveis por Análise Fatorial, o método de aprendizagem para gerar as regras de transição por Regressão e a técnica de projeção das mudanças baseada em *Exogenous Quantity*.

O método de Análise Fatorial é considerado um método de análise multivariada, uma vez que utiliza de técnicas estatísticas que analisam mais de duas variáveis simultaneamente. Tais

variáveis devem apresentar características que as classifiquem como aleatórias e devem ser inter-relacionadas de tal maneira que seus diferentes efeitos não possam ser significativamente interpretados em separado (HAIR, J. F., 2009; FOWLER, H. G., 1993; JOHNSON, R. A. & WICHERN, D. W. 1988).

A metodologia de “*Exogenous quantity*” indica que o modelador especificará o valor quantitativo que cada categoria terá no mapa de predição, e que esta predição será independente da localização inicial das categorias. O valor a ser informado pode ser calculado usando diferentes técnicas, tais como Regressão Linear, Regressão Logística ou mesmo a Cadeia de Markov (BREDEWEG, et al, 2007; GEOGRAPHICAL SCIENCES COMMITTEE et al, 2014; GOMES, 2013; PONTIUS JR. et al, 2008). Como o método desconsidera a localização inicial da classe a ser projetada, é necessária a associação da técnica com outra que possa identificar as regras de transição e que responda pela condição espacial. No caso deste artigo, a metodologia adotada é a Regressão, *default* do módulo Geomod/Idrisi.

No Geomod, as mudanças futuras são mapeadas baseando-se no comportamento dos vizinhos mais próximos, ou de acordo com a *Suitability Image*, que informa o potencial de mudança de acordo com as variáveis explicativas.

2. MATERIAS E MÉTODOS

Inicialmente, foram estruturadas bases cartográficas com a finalidade de representar as variáveis que melhor respondem pelo objetivo de investigação. As bases cartográficas utilizadas neste artigo apresentam as seguintes padronizações de formato, escala e sistema de referência cartográfica:

- Todas as camadas apresentam a mesma resolução espacial (pixel 5 x 5 metros);
- Todas as camadas apresentam o sistema de projeção cartográfica - WGS 84/Fuso 23S;
- Todas as camadas apresentam o mesmo retângulo envolvente, número de linhas e colunas na matriz;
- Todas as camadas foram convertidos para o formato numérico inteiro (*Integer*) e configuram-se como variável numérica categórica;
- Todas as variáveis variam na mesma escala numérica (de zero à dez), onde zero é o menor potencial de mudança e dez o maior potencial, ou seja, elas foram normalizadas.

As plataformas utilizadas para elaborar as análises foram:

- STATA/MP 12.1 – Análise Fatorial - seleção das variáveis
- Geomod/Idrisi Selva –Modelo de mudança

As bases cartográficas disponibilizadas para este estudo foram:

Tabela 1: Relação das bases cartográficas utilizadas no artigo⁶

Camada	Fonte
Potencial de Transformação por Distância das Operações Urbana	Shapefile das Operações Urbanas, cedida pela PBH
Potencial de Transformação de Ocupação Volumétrica por lote	Shapefile de Lotes da Pampulha: atributos referentes ao Coeficiente de aproveitamento por lote, cedida pela PBH
Densidade de Comércio	Shapefile de Postes (Projeto Gemini): atributo informando o uso dado à energia elétrica, cedida pela Cemig
Potencial de Transformação do Zoneamento	Shapefile do Zoneamento Urbanístico, cedida pela PBH
Acessibilidade e Capilaridade	Shapefile das Tipologias de vias, cedida pela PBH
Densidade de Projetos Aprovados na PBH	Shapefile dos projetos aprovados na PBH, cedida pela PBH
Potencial de Transformação da Vegetação Densa	Matriz de probabilidade de Mudança por Cadeia de Markov calculada a partir dos mapas de cobertura do solo de 2009 e 2011 – Fonte – Imagens RapidEye, IEF e Lab de Geoprocessamento da EA
Potencial de Transformação da Vegetação Rasteira	Matriz de probabilidade de Mudança por Cadeia de Markov calculada a partir dos mapas de cobertura do solo de 2009 e 2011 – Fonte – Imagens RapidEye, IEF e Lab de Geoprocessamento da EA

2.1 – Análise fatorial na escolha das variáveis explicativas

A Análise Fatorial é uma técnica de interdependência cujo propósito principal é definir a estrutura inerente entre as variáveis na análise em um único conjunto (HAIR, J. F., et al., 2009; KIM, J.O.,1975). Neste artigo, na Análise Fatorial considerou-se como fator de exclusão da variável no modelo aquelas que apresentassem *UNIQUENNESS* maior ou igual a 0.6, tanto para o teste geral como para o teste de cada variável individual (MINGOTI, 2005). Para realizar o procedimento as variáveis foram retiradas da Análise Fatorial uma por vez, de modo a favorecer que a de maior valor fosse eliminada a cada rodada. O procedimento contou com duas rodadas, e os resultados da análise das variáveis que foram selecionadas para compor o Modelo de Simulação são:

⁶ Para maiores detalhes sobre as bases cartográficas, vide o artigo 1 “*Comparação entre métodos de análise multivariada na seleção de variáveis explicativas para compor um Modelo de Mudança da Paisagem – Aplicações na Pampulha, Brazil*”.

Tabela 2: Primeira rodada da Análise fatorial – análise do comportamento das variáveis explicativas disponíveis

Factor	Eigenvalue	Difference	Proportion	Cumulative
Factor1	2.60302	1.28491	0.3254	0.3254
Factor2	1.31811	0.27652	0.1648	0.4901
Factor3	1.04159	0.16394	0.1302	0.6203
Factor4	0.87766	0.16385	0.1097	0.73
Factor5	0.7138	0.10327	0.0892	0.8193
Factor6	0.61053	0.14534	0.0763	0.8956
Factor7	0.46519	0.0951	0.0581	0.9537
Factor8	0.37009	.	0.0463	1

LR test: independent vs. saturated: $\chi^2(28) = 3.3e+05$ Prob> $\chi^2 = 0.0000$

A tabela 2 demonstra as oito variáveis disponíveis para o estudo. Os autovalores (*Eigenvalues*) indicam o total da variância no modelo causado por variável. Variáveis com alta variância indicam que a mesma é importante para a composição do modelo. Variáveis que pouco contribuem para a performance do modelo apresentam baixa variância (LONG & FREESE, 2006; HAIR, J. F. et al, 2009). Desta forma, as variáveis de maior variância e que portanto devem compor o modelo final são: Potencial de Transformação por Distância das Operações Urbanas, Potencial de Transformação de Ocupação Volumétrica por Lote e Potencial de Transformação do Zoneamento.

Ainda na tabela 2 cabe avaliar o campo *Proportion*, que indica o percentual do modelo que é explicado pelas variáveis explicativas. O campo *Proportion* está diretamente relacionado com o campo *Eigenvalues*, informando que cerca de 32% do modelo é respondido pela variável Potencial de Transformação por Distância das Operações Urbanas, 16% pela variável Potencial de Transformação de Ocupação Volumétrica por Lote e 13% com a variável Potencial de Transformação do Zoneamento.

As cargas fatoriais (*Factors*) são as correlações entre as variáveis originais e os fatores. Os fatores correspondem aos agrupamentos de variáveis que melhor respondem pela variância do modelo. Este é um dos principais pontos da Análise Fatorial e indica que quanto maior a carga fatorial, maior será a correlação com determinado fator. Um valor negativo na carga fatorial indica uma correlação inversa entre as variáveis originais e os fatores.

A quantidade de cargas fatoriais é automaticamente calculada pelo STATA com base nos autovalores (critério de *Kaiser*). Já a especificidade ou erro (*Uniqueness*) é a parcela da variância (correlação) dos dados que não pôde ser explicada pelo fator, ou seja, é a proporção

única da variável não compartilhada com as outras variáveis (LONG & FREESE, 2006; HAIR, J. F. et al, 2009). Segundo Mingoti (2005), valores *Uniqueness* maior que 0.6 devem ser retirados da Análise Fatorial.

Tabela 3: Primeira rodada da Análise fatorial – Cargas fatoriais e Erro

Variável	Factor1	Factor2	Factor3	Uniqueness
Potencial de transformação por distância das Operações Urbanas	0.7332	-0.2275	0.1461	0.3893
Potencial de transformação de ocupação volumétrica por lote	0.4871	0.0536	-0.3651	0.6265
Potencial de transformação do Zoneamento	0.6871	0.1298	0.1235	0.4958
Acessibilidade e Capilaridade	0.7693	0.3508	0.0687	0.2804
Densidade de projetos aprovados na PBH	0.5787	0.5595	0.0658	0.3477
Densidade de Comércio	-0.5656	0.5961	-0.0176	0.3244
Potencial de transformação da Vegetação Densa	0.0876	-0.4211	0.738	0.2703
Potencial de transformação da Vegetação Rasteira	0.3188	-0.5272	-0.5636	0.3028

Na primeira rodada da Análise Fatorial, o fator 1 apresenta influência predominantemente positiva no modelo, já que apresenta correlação inversa apenas com a variável Densidade de Comércio. O fator 2 e o fator 3 apresentam correlação inversa com três variáveis originais. No caso do fator 2 as variáveis correspondem às Operações Urbanas, as transformações potenciais de Vegetação Densa e potencial de transformação de Vegetação Rasteira. Já com o fator 3, as correlações inversas se dão com as variáveis Potencial de Transformação de Ocupação Volumétrica por Lote, Densidade de Comércio e transformações potenciais de Vegetação Rasteira. A avaliação do *Uniqueness* indicou que a única variável que apresenta uma parcela da variância dos dados que não pode ser explicada pelo fator acima de 0.6 é o Potencial de Transformação de Ocupação Volumétrica por Lote. Por este motivo, essa variável foi retirada na segunda rodada da análise fatorial (Tabela 4 e 5).

Tabela 4: Segunda rodada da Análise fatorial – análise do comportamento das variáveis explicativas selecionadas

Factor	Eigenvalue	Difference	Proportion	Cumulative
Factor1	2.44303	1.12603	0.3490	0.3490
Factor2	1.31700	0.30468	0.1881	0.5371
Factor3	1.01213	0.23320	0.1446	0.6817
Factor4	0.77893	0.16730	0.1113	0.7930
Factor5	0.61163	0.14498	0.0874	0.8804
Factor6	0.46665	0.09603	0.0667	0.9471
Factor7	0.37063	.	0.0529	1.000

LR test: independent vs. saturated: $\chi^2(21) = 3.0e+05$ Prob> $\chi^2 = 0.0000$

Tabela 5: Segunda rodada da Análise fatorial – Cargas fatoriais e Erro

Variable	Factor1	Factor2	Factor3	Uniqueness
Potencial de transformação por distância das Operações Urbanas	0.7631	-0.2104	0.0204	0.373
Potencial de transformação do Zoneamento	0.6905	0.1385	0.1217	0.4892
Acessibilidade e Capilaridade	0.779	0.3631	-0.0086	0.2613
Densidade de projetos aprovados na PBH	0.5787	0.5675	0.0254	0.3424
Densidade de Comércio	-0.5833	0.5861	0.0554	0.3131
Potencial de transformação da Vegetação Densa	0.1044	-0.4116	0.8381	0.1173
Potencial de transformação da Vegetação Rasteira	0.3016	-0.5354	-0.5392	0.3317

A tabela 5 demonstra que uma vez retirado a variável Potencial de Transformação de Ocupação Volumétrica por Lote, nenhuma outra variável apresentou *Uniqueness* maior que 0.6. Desta forma, ao avaliar a participação das variáveis nos Fatores 1, 2 e 3 (tabela 5) observa-se que o fator 1 é o agrupamento das variáveis Potencial de Transformação por Distância das Operações Urbanas, Potencial de Transformação do Zoneamento, Acessibilidade e Capilaridade e Densidade de projetos aprovados na PBH. O fator 2 é composto por Potencial de Transformação por Distância das Operações Urbanas, Densidade de Comércio e Potencial de Transformação da Vegetação Rasteira e o fator 3 corresponde pela variável Potencial de Transformação da Vegetação Densa.

Tabela 6: Análise fatorial - com rotação Varimax ortogonal

Variable	Factor1	Factor2	Factor3	Uniqueness
Potencial de transformação por distância das Operações Urbanas	0.5304	0.5509		0.373
Potencial de transformação do Zoneamento	0.6663			0.4892
Acessibilidade e Capilaridade	0.8465			0.2613
Densidade de projetos aprovados na PBH	0.791			0.3424
Densidade de Comércio		-0.768		0.3131
Potencial de transformação da Vegetação Densa			0.9382	0.1173
Potencial de transformação da Vegetação Rasteira		0.7771		0.3317

O fator 1 apresenta correlação positiva entre as variáveis que compõem este fator, ou seja, as Transformações por Distância de Operações Urbanas estão presentes segundo o maior Potencial de Transformação do Zoneamento, que por sua vez está correlacionado com a maior oferta de Acessibilidade e Capilaridade, assim como a densidade de Projetos Aprovados.

O fator 2 apresenta correlação positiva entre as transformações de Distância a Operações Urbanas e Potencial de Transformação de Vegetação Rasteira, ou seja, as operações urbanas ocorrem onde há maior possibilidade de substituir a vegetação rasteira pelas operações urbanas, e em correlação negativa com a Densidade de Comércio, já que não há o objetivo de

retirar os centros comerciais já instalados para substituir pelas obras urbanas.

O fator 3 é constituído pelos núcleos de vegetação densa, que se mostram estáveis na paisagem urbana da Pampulha. Desta forma, os três fatores criados pela análise fatorial identificaram o comportamento e as correlações das variáveis originais, o que auxiliou na compreensão das dinâmicas de mudanças na cobertura do solo da área de estudo, tornando possível a organização do Modelo de Simulação da Paisagem da Pampulha no Geomod.

3. GEOMOD – MODELO DE SIMULAÇÃO DA PAISAGEM URBANA DA PAMPULHA

O Geomod é um Modelo de Simulação da Paisagem que simula a locação espacial das mudanças no uso/cobertura do solo de um estágio para outro (PONTIUS e CHEN, 2006; PONTIUS e MALANSON, 2005). De acordo com Pontius e Millones (2011), o modelo opera de maneira a distinguir claramente entre a quantidade de mudanças na paisagem e a localização espacial destas mudanças.

O GEOMOD simula as mudanças entre exatamente duas categorias, neste artigo, urbano e não urbano. Exige como dados de entrada no mínimo duas imagens raster da cobertura/uso do solo e a especificação das quantidades das mudanças ocorridas entre as classes no tempo final, através da metodologia *Exogenous Quantity*. No que se refere às regras de transição, o GEOMOD exige a entrada de uma *Suitability Image* ou imagem de propensão a mudança, a qual pode ser externa ao modelo ou criada por *Multicriterio Analysis* desenvolvida no próprio módulo. Segundo Eastman (2012), a seleção dos *pixels* que definirão a localização espacial das mudanças podem seguir uma das metodologias:

In the unconstrained mode, GEOMOD selects pixels to be developed based on the suitability map only. In the constrained mode, GEOMOD constrains the selection of pixels to be developed to only those pixels that are near the border of categories 1 and 2 (EASTMAN, 2012).

Neste artigo, optou-se pelo método que considera a locação das mudanças nas bordas da classe urbano para não urbano, aplicando um filtro de vizinhança 3x3.

3.1 Análise de Multicritério e a *Suitability Image*

Segundo Moura (2007), a análise de multicritérios é um procedimento metodológico de cruzamento de variáveis amplamente aceito nas análises espaciais. Baseia-se na integração de variáveis estruturada segundo uma “*Árvore de Decisões*” e cujas combinações pode seguir

uma “*Análise Hierárquica de Pesos*” ou outro critério para se definir o peso ou importância de cada variável. O procedimento baseia-se no mapeamento de variáveis por plano de informação e na definição do grau de pertinência de cada plano de informação e de cada um de seus componentes de legenda para a construção do resultado final. A matemática empregada é a média ponderada simples, mas há pesquisadores que utilizam a lógica Fuzzy para atribuir os pesos e notas.

A elaboração do mapa de propensão às mudanças na cobertura do solo da regional Pampulha considerou as sete variáveis explicativas selecionadas no método de Análise Fatorial, seguida da atribuição de pesos equivalentes por acreditar que todas exercem influência similar nas mudanças da cobertura do solo.

4. RESULTADOS E DISCUSSÃO:

Os resultados são apresentados através dos índices de validação do modelo (Figura 1), o mapa real e projetado da Pampulha para o ano de 2013 (Figura 2), o mapa de propensão às mudanças na cobertura do solo da regional Pampulha (Figura 3) e o projetado para o ano de 2020 (Figura 4). A figura 1 demonstra que o modelo é aceito uma vez que apresentando índices de validação superiores a 95% (PONTIUS, R.G. 2000; PONTIUS, R.G. 2002; PONTIUS JR, R.G. & SUEDEMEYER, B.; 2004) em todos os aspectos analisados, como explica Pontius, R.G.; M. Millones. (2011) e Eastman (2012)⁷

⁷ [1] Kappa for no information (denoted *Kno*), [2] Kappa for grid-cell level location (denoted *Klocation*), and [3] Kappa for stratum-level location (denoted *KlocationStrata*). All of these statistics are linear functions of points in the *VALIDATE* output. Specifically, $Kno = \{M(m)-N(n)\}/\{P(p)-N(n)\}$. $Klocation = \{M(m)-N(m)\}/\{P(m)-N(m)\}$. $KlocationStrata = \{M(m)-H(m)\}/\{K(m)-H(m)\}$. *Klocation* indicates how well the grid cells are located on the landscape. *KlocationStrata* indicates how well the grid cells are located within the strata.

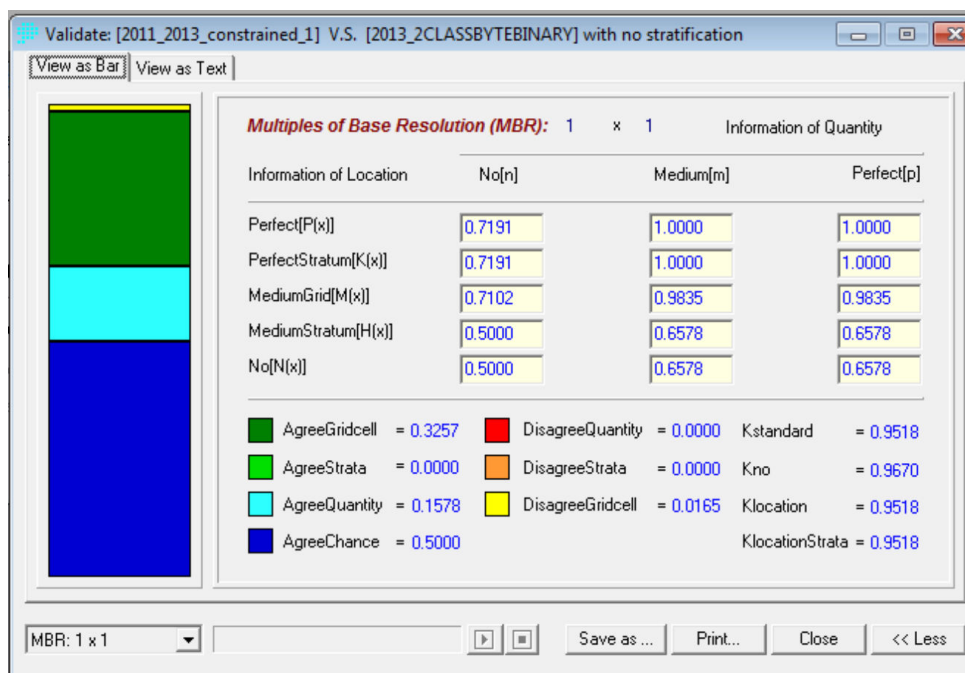


Figura 1: Validação do Modelo de Simulação da Pampulha no módulo GEOMOD

Na comparação entre o mapa projetado e o real da Pampulha para o ano de 2013 pode-se verificar que a semelhança dos dois é realmente significativa.




Figura 27: Comparação entre o mapa Real e projetado da Pampulha para o ano de 2013

A figura 3 apresenta o mapa de propensão às mudanças na cobertura do solo considerando as variáveis principais selecionadas por análise fatorial. O mapa está organizado de forma a identificar as áreas de maior propensão às mudanças com tons vermelhos, e de menor propensão de tons azulados a esverdeados. O mapa indica que a área na regional que deve receber maior atenção quanto a possíveis futuras alterações na cobertura do solo refere-se à porção noroeste da regional, próximo à divisa com Contagem, no entorno da Lagoa da Pampulha e nas áreas próximas ao campus da UFMG na Pampulha.




Figura 3: Mapa de aptidão às mudanças considerando as variáveis drivers

O mapa projetado da cobertura do solo da Regional Pampulha considerando um crescimento de 3% ou um aumento de 2.7194 Km² da mancha urbana em 2020 é apresentado na figura 4, acompanhada do mapa da espacialização das mudanças.

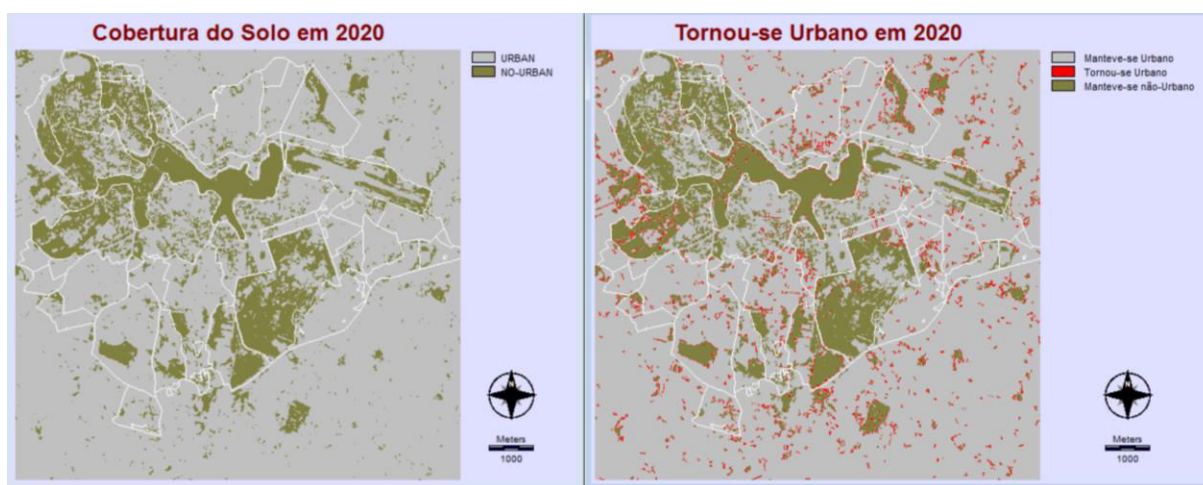


Figura 4a: Mapa projetado da cobertura do solo para 2010; **4b:** Mapa de Tornou-se urbano

O mapa de cobertura do solo da Pampulha em 2020 (Figura 4a) demonstra a existência de uma tendência de manutenção dos grandes fragmentos, tornando estas feições estáveis na composição da paisagem. O mapa das transformações (Figura 4b) demonstra que a expansão da mancha urbana da Pampulha não se encontra concentrada em um lugar específico, mas as mudanças estão relacionadas aos pequenos fragmentos de uso não urbano que serão substituídos pelo uso urbano. Vale ressaltar, entretanto, que as mudanças verificadas relacionam-se apenas à expansão horizontal da mancha urbana, e não ao processo de verticalização, muito comum em Belo Horizonte.

5. CONSIDERAÇÕES FINAIS

O processo de modelagem das transformações no uso/cobertura do solo é uma ferramenta extremamente importante para apoio à tomada de decisão no processo de planejamento urbano. Apesar de pouco usado para estes fins no Brasil, a técnica é amplamente aceita junto à comunidade internacional.

Como o ambiente urbano é extremamente complexo, verifica-se dificuldades na organização dos Modelos de Simulação, haja vista que é necessário identificar quais são e como se dá o comportamento das variáveis que respondem pelo fenômeno. Esta etapa demanda dedicação e necessita do apoio de especialistas que conhecem a área de estudo para ajudar na composição e interpretação do modelo. A Análise Fatorial aplicada com o intuito de selecionar as variáveis que melhor respondem pelo modelo mostrou ser um método eficiente, auxiliando não apenas na seleção das variáveis mas também na inter-relação entre elas.

O Geomod como Modelo de Simulação mostra-se como uma alternativa mais simples da modelagem, já que os dados iniciais requeridos são poucos. No caso de estudos urbanos, o objetivo de se aplicar um Modelo de Simulação é entender como acontecem as correlações entre as variáveis e o grau de influência destas nas transformações das tipologias de uso/cobertura do solo. Portanto, aconselha-se a aplicação do Geomod para estudos exploratórios, já que não há a possibilidade de aplicá-lo frente a um mapeamento que considere mais do que duas tipologias de uso/cobertura do solo.

Sobre a Pampulha observa-se que a taxa de crescimento horizontal da mancha urbana é baixo (cerca de 0.5% ao ano), entretanto a taxa de crescimento vertical é bem maior. Desta forma, o método responde bem pela projeção de expansão horizontal em processo de espraiamento, mas caberiam outras investigações que considerassem o crescimento por densificação e verticalização. Indica-se, como desdobramentos futuros da investigação, o investimento em modelagem também dos impactos da verticalização na paisagem urbana.

REFERÊNCIAS:

- BREDEWEG, Bert; SALLES, Paulo; NUTTLE, Tim. **Using exogenous quantities in qualitative models about environmental sustainability**. *AI Communications*, v. 20, n. 1, p. 49-58, 2007.
- EASTMAN, J. R. **IDRISI Selva Manual**. Clark University. Sitio web: www.clarklabs.org, 2012.
- FOWLER, H. G. **A novel application of factor analysis to examine interactions of the fossorial predators *Sirthenia striata* (Hemiptera: Reduviidae) and *Megacephala fulgida* (Coleoptera: Cicindelidae)**. *Rev. Mat. Estat.* 11:93-103, 1993.
- GEOGRAPHICAL SCIENCES COMMITTEE et al. **Advancing Land Change Modeling: Opportunities and Research Requirements**. National Academies Press, 2014.
- GOMES, Paula Madeira. **Modelagem da dinâmica do uso da terra e instrumentos de Política Ambiental: a expansão da cana-de-açúcar na Bacia Hidrográfica do Tiete/Jacaré (UGRHI 13)**. 2013. Tese de Doutorado. Universidade de São Paulo.
- HAIR, Joseph F., et al. **Análise multivariada de dados**. Bookma, 2009
- JOHNSON, R. A. & WICHERN, D. W. **Applied multivariate statistical analysis**. Englewood Cliffs, N. J., Prentice-Hall, Inc., 1988. 607 p.
- KIM, J.O. **Factor analysis**. In: NIEH, H.; HULL, C.H. ; JENKINS, J.C.; STENBRENNER, K.; BENJ, D.H. (eds.). *Statistical package for social sciences*. New York. Megal Hill, 1975. v 5. p 468-514.
- LONG, J. Scott; FREESE, Jeremy. **Regression models for categorical dependent variables using Stata**. Stata press, 2006.
- MINGOTI, Sueli Aparecida. **Análise de dados através de métodos de estatística multivariada: uma abordagem aplicada**. Editora UFMG, 2005.
- MOURA, Ana Clara M. **Reflexões metodológicas como subsídio para estudos ambientais baseados em Análise de Multicritérios**. In: Brazilian conference of remote sensing. 2007. p. 2899-2906.
- PONTIUS, R.G.AND M. MILLONES. **Death to Kappa: birth of quantity disagreement and allocation disagreement for accuracy assessment**. *International Journal of Remote Sensing*; 2011.
- PONTIUS JR, Robert Gilmore et al. **Comparing the input, output, and validation maps for several models of land change**. *The Annals of Regional Science*, v. 42, n. 1, p. 11-37, 2008.
- PONTIUS, R. G. J.; CHEN, H. **GEOMOD Modeling**. Land-use and cover change modeling. Note on GEOMOD modeling available within IDRISI Andes package. 2006.
- PONTIUS, R. G.; MALANSON, J. **Comparison of the structure and accuracy of two land change models**. *International Journal of Geographical Information Science*, v. 19, n. 2, p. 243-265, 2005.
- PONTIUS JR, R.G. & SUEDEMEYER, B. **Components of agreement in categorical maps at multiple resolutions**. In R S Lunetta and J G Lyon (eds). *Remote Sensing and GIS Accuracy Assessment*. CRC Press, Boca Raton FL. p.233-251; 2004.

PONTIUS, R.G. **Statistical methods to partition effects of quantity and location during comparison of categorical maps at multiple resolutions.** *Photogrammetric Engineering & Remote Sensing*, 68(10): 1041-1049; 2002.

PONTIUS, R.G. **Quantification error versus location error in comparison of categorical maps.** *Photogrammetric Engineering & Remote Sensing*, 66(8): 1011-1016; 2000.

Artigo 03: Construção de Cenários para a Regional Pampulha por Cadeia de Markov e Autômatos Celular: projeção das alterações na cobertura do solo

Construção de Cenários para a Regional Pampulha por Cadeia de Markov e Autômatos Celular: projeção das alterações na cobertura do solo

G. Carvalho^{1,2*}, A.C.M.Moura²

¹Geoscience College, Geography Department, Federal University of Minas Gerais, 31270-901, Pampulha – Belo Horizonte, Minas Gerais, Brazil

²GIS Laboratory, Architecture College, Urban Planning Department, Federal University of Minas Gerais, Federal University of Minas Gerais, 30130-140, Savassi – Belo Horizonte, Minas Gerais, Brazil

*Corresponding author: E-mail: grazielleac@ufmg.br, Tel +55 31 3409-8827

Resumo

Uma das metodologias que se têm destacado no cenário internacional para estudos que envolvem as dinâmicas urbanas refere-se ao uso dos modelos dinâmicos da paisagem. Os estudos de simulação das mudanças nas paisagens urbanas permitem a construção de cenários futuros, apoiam o gestor na projeção de sua ação e na identificação dos impactos que a mesma causará antes da sua implementação. Este trabalho tem como objetivo a elaboração e comparação de dois cenários possíveis para a Regional Pampulha – Belo Horizonte no ano de 2020: o cenário 1 considera que o padrão da cobertura do solo na regional continuará o mesmo verificado nos últimos 5 anos; e o cenário 2 considera que as alterações na cobertura do solo se darão devido à implantação de uma nova via de fluxo rápido na regional. A metodologia usada no presente trabalho é baseada em Cadeia de Markov, na definição das regras de transição e em Celular Autômata para a locação das mudanças no território. Em ambas as simulações os resultados mostraram que a porção noroeste da regional apresenta-se como a que mais necessitará de atenção pelos gestores.

Palavras Chaves: Planejamento Urbano, Modelo de Mudança, Cadeia de Markov, Automato Celular, Pampulha

1. INTRODUÇÃO

O Brasil tornou-se um país predominantemente urbano na década de 1970, vindo a alcançar o percentual de 84% de sua população residente em cidades no ano de 2010. Diante deste cenário, é cada vez maior a necessidade de se obter um novo olhar para se pensar e fazer o planejamento das cidades no Brasil. Com a maior concentração de pessoas e serviços no ambiente urbano, tem-se observado a intensificação dos chamados “problemas urbanos”, que ainda são pensados pelos gestores de forma isolada e desconexa. Desta forma, faz-se necessário compreender como estes interagem entre si, no tempo e no espaço, e como influenciam o/no sistema de uma forma geral.

Uma das metodologias que se têm destacado no cenário internacional para estudos que envolvem as dinâmicas urbanas refere-se ao uso dos modelos dinâmicos da paisagem. Estes

constituem-se como uma das melhores técnicas disponíveis para responder a necessidades e interesses das investigações acerca de dinâmicas de uso do solo urbano e regional (DE ALMEIDA, MONTEIRO & CÂMARA, 2007). Os estudos de simulação de mudanças nas paisagens urbanas, que permitem a construção de cenários futuros, apoiam o gestor na projeção de sua ação e na identificação dos impactos que a mesma causará antes da sua implementação.

A metodologia usada no presente trabalho é baseada em Cadeia de Markov, na definição das regras de transição, e em Autômato Celular, para localização das mudanças. O objetivo é a definição da localização geográfica das mudanças na cobertura do solo. A modelagem utiliza a ferramenta CA-Markov, disponível no software IDRISI SELVA, para identificar tendências de mudanças na cobertura do solo da Regional Pampulha para o ano de 2020. Para sua execução foi feito o levantamento dos dados iniciais necessários para se criar o modelo, com vistas a responder aos questionamentos dos pesquisadores e/ou gestores quanto às mudanças para a regional, considerando dois cenários: Cenário 1: que o padrão da cobertura do solo na regional continuará o mesmo verificado nos últimos 5 anos; Cenário 2: alterações na cobertura do solo devido à implantação de uma nova via de fluxo rápido na regional.

2. ÁREA DE ESTUDO – PAMPULHA – BELO HORIZONTE, MINAS GERAIS

A cidade de Belo Horizonte – Minas Gerais, destaca-se no cenário brasileiro no que se refere a trabalhos e pesquisas com o gerenciamento de dados geográficos, uma vez que esta é uma política pública presente na capital desde os anos de 1974, com a criação da PRODABEL. Com o objetivo de demonstrar as potencialidades e limitações da aplicação de estudos de simulação urbanística no Brasil, é utilizada a Regional Pampulha (Fig.01), em Belo Horizonte, como um estudo de caso.

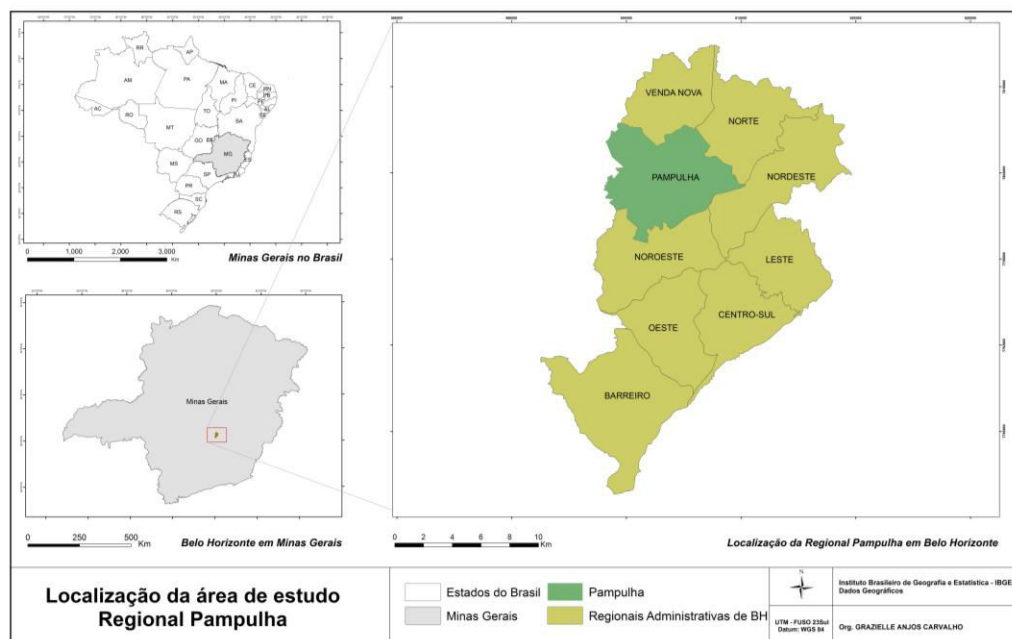


Figura 28: Localização da área de estudo – Regional Pampulha

Situada na região Norte de Belo Horizonte e com alto valor imobiliário, a Pampulha tem atraído investidores nos últimos anos, levando a um maior dinamismo na conformação e transformação paisagística. O resultado são os conflitos urbanos, ambientais, arquitetônicos e culturais, todos no mesmo espaço, o que justifica a sua escolha como objeto de estudo neste trabalho.

3. MATERIAIS

A modelagem de cenários futuros em sistema urbano ou ambiental se dá com o intuito de identificar as alterações na conformação da paisagem existente a partir de uma determinada política pública a ser implantada. A simulação da ação em ambiente computacional favorece possíveis readequações do projeto antes de sua implementação, minimizando o impacto na sociedade e no meio ambiente.

Os Modelos de Simulação da paisagem apresentam como dados básicos essenciais: o mapeamento do uso ou da cobertura do solo e as variáveis explicativas do objeto de estudo. Como pré-requisitos iniciais ao processo de modelagem, os dados foram configurados considerando os seguintes aspectos:

- Os dados foram configurados no mesmo sistema de projeção cartográfica (UTM - SIRGAS 2000, fuso 23S);
- Os dados convertidos para o mesmo formato (matricial);

- Os dados apresentam o mesmo retângulo envolvente (coordenadas do canto superior e inferior devem ser iguais, inclusive nas casas decimais, além de mesmo número de linhas e colunas);
- O tamanho do pixel é o mesmo em todas as matrizes (5 metros), para favorecer as análises;
- Os dados foram normalizados em uma mesma escala numérica, onde valores menores indiquem menor potencial de mudança e valores maiores indiquem maior potencial de mudança;

Para elaboração do mapa de cobertura do solo da Pampulha foram utilizadas imagens RAPID EYE, resolução espacial de 5m x 5m, cena 2329919, dos anos 2009, 2011 e 2013. Como metodologia de classificação do uso do solo fez-se uma pré-classificação supervisionada (MAXVER) orientada a objetos no software SPRING/INPE para o ano de 2009, com a definição prévia de 4 classes de cobertura do solo, sendo as classes definidas como: Antropizado, Vegetação Densa, Vegetação Rasteira e Água. Converteu-se o mapa do formato raster para shapefile e em seguida, fez-se a validação do mesmo, corrigindo a classificação automática por inspeção visual, alterando na tabela de atributos os dados classificados erroneamente.

Finalizada a correção do mapa de 2009, partiu-se deste para a classificação do mapa de 2011, alterando somente os polígonos onde realmente houve mudanças, identificados por inspeção visual, evitando assim erros de classificação automática. O mesmo processo foi realizado a partir dos dados de 2011 para os dados de 2013 (Fig. 08). Finalizado este processo, os arquivos vetoriais foram convertidos para o formato raster, para aplicação do processo de modelagem dinâmica, composta pela organização do modelo, etapas de calibração, validação e projeção futura.

Para análise dos cenários projetados, buscou-se compreender, através das seguintes variáveis explicativas e/ou catalizadoras, o comportamento das mudanças:

- Kernel dos pontos que representam mais de cinco atividades Comerciais por poste – Fonte: Cemig
- Zoneamento da Pampulha – Fonte: Prodabel/PBH
- Potencial de transformação segundo a disponibilidade de lotes vagos e residências de até 1 andar na Pampulha – Fonte: Prodabel/PBH

4. MÉTODOS: CADEIA DE MARKOV E AUTÔMATO CELULAR

O método de Cadeia de Markov é comumente usado com o de Autômatos Celulares. Aplica-se o método de Cadeia de Markov para a definição das regras de transição (matriz de probabilidade de mudança) e aplica-se o método de Autômatos Celulares para a definição do caráter espacial da mudança, considerando o uso/cobertura do solo inicial dos vizinhos mais próximos.

Quando o território de distribuição dos estados é representado de modo discreto (qualitativo) então o modelo de Markov é denominado de “Cadeia de Markov”. As propriedades desses modelos são estudadas em termos das propriedades das matrizes de transições de estados que são utilizadas na sua descrição. Esta matriz é dinâmica, pois permite que as probabilidades de transição se modifiquem em função do tempo “t”, onde “t” é discreto, ou seja, descontínuo. (EL YACOUBI, 2006; DIMURO et al., 2002).

Cadeias de Markov são modelos matemáticos para descrever processos estocásticos, o que significa que o estado é indeterminado, com origem em eventos aleatórios. São assim descritos:

$$\Pi(t+1) = P_n \cdot \Pi(t)$$

Equação 1

Onde $\Pi(t)$ é o estado do sistema no tempo t, $\Pi(t+1)$ é o estado do sistema após o intervalo t+1 e P_n são os estados passíveis de acontecer, que são representados em matrizes de possibilidades de transição. Essas matrizes de transição representam a possibilidade de um determinado estado i permanecer o mesmo ou mudar para o estado j durante o intervalo de tempo t -> t+1.

As probabilidades de transição são usualmente derivadas de amostras relativas a um certo intervalo de tempo. As Cadeias de Markov de 1ª ordem assumem que o estado futuro do sistema depende apenas do seu estado presente e das possibilidades de transição, sendo independente da trajetória que o levou aquele estado. Este modelo não ignora o passado, mas assume que toda a informação do passado está concentrada no presente. Desta forma, as interações são instantâneas, sendo irrelevante o tempo de permanência das variáveis em cada estado (SOARES FILHO, 1998).

Um Autômato Celular é uma entidade celular que varia seu estado de forma independente, considerando apenas o seu estado anterior e o estado de seus vizinhos imediatos de acordo com uma regra específica (BATTY, et al., 1999; BURROUGH, 1998; CÂMARA, 1996; ENGELEN, 1995; O’SULLIVAN & TORRENS, 2000; ROY, 1996;).

A metodologia dos Autômatos Celulares propõe uma rede regular de células idênticas, onde cada uma pode estar em um de um número finito de estados discretos, em intervalos de tempo discretos, na sua evolução. Neste modelo, parte-se de um estado inicial aleatório, onde com o passar do tempo ($T1 \rightarrow T2$), novas células nascem e algumas morrem. O que determina o estado de uma célula é sua vizinhança que, neste caso, é definida por, no mínimo, quatro células adjacentes. Desta forma, parte do princípio que padrões espaciais globais emergem de ações locais (COUCLELIS, 1985; GEOGRAPHICAL SCIENCES COMMITTEE, 2014; O’SULLIVAN & TORRENS; 2000; PONTIUS JR. et al, 2008; TOBLER, 1979;).

Nos últimos anos, os conceitos de Autômatos Celulares e Cadeia de Markov têm sido utilizados para modelar fenômenos, tais como o espalhamento de epidemias (MELOTTI, 2009; SASSO, et al., 2004), os desmatamentos (XIMENES et al., 2008; SOARES-FILHO et al., 2003), dinâmicas de mudança no uso do solo em áreas agrícolas (MACEDO et al., 2013; KAMUSOKO, COURAGE et al., 2009), simulação de tráfego e transporte (LIMA, 2007; SUN et al., 2012), dinâmicas de mudança no uso do solo urbano (ALMEIDA et al., 2003; BATTY, et al 1999; BURROUGH, 1998; CÂMARA, 1996; COUCLELIS, 1997; ENGELEN, 1995; FUGLSANG et al., 2013; MARIA DE ALMEIDA, et al., 2003; MEMARIAN et al., 2012, MITSOVA et al., 2011; ONSTED e CHOWDHURY, 2014; PERES e POLIDORI, 2009; ROY, 1996; VERSTEGEN et al., 2014), além de estudos de população, espaço e ambiente (UMBELINO, G., & BARBIERI, A., 2010) e modelagem de expansão da mancha urbana para regiões metropolitanas (WHITE e ENGELEN, 1997; UMBELINO, 2012; FURTADO & VAN DELDEN, 2011).

Exemplos de plataformas que oferecem esta técnica são: Agent Analyst, Dinâmica, Dynamic Urban Evolution Modeling (DUEM), IDRISI (módulos CellAtom e CA-Markov, sendo somente o CellAtom de metodologia exclusiva de Autômatos Celulares), Land Transformation Model (LTM), Simulador do Ambiente da Cidade (SACI), Urban Growth Analysis Tool (UGAT), Metronâmica, LUCIA (Land Use Change Impact Assessment), ou

vários outros aplicativos gratuitos que podem ser encontrados no link: (http://uncomp.uwe.ac.uk/genaro/Cellular_Automata_Repository/Software.html)

A organização do modelo de projeção do uso do solo da Pampulha foi realizado com o emprego do IDRISI, através da ferramenta CA-MARKOV. Os fluxogramas (Fig. 02, 03 e 04) descrevem as duas etapas deste processo de modelagem:

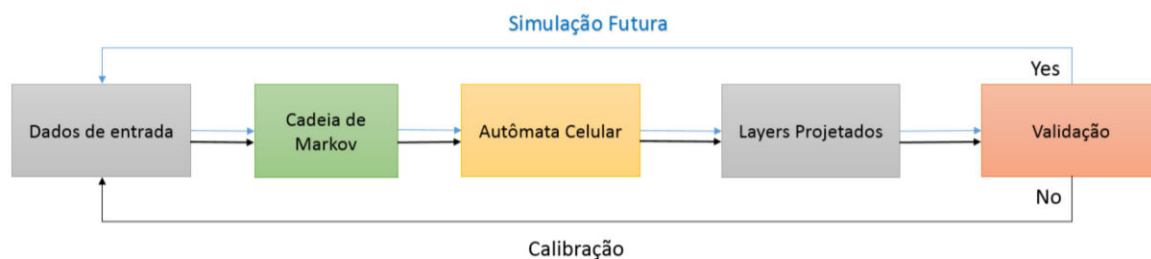


Figura 2: Fluxograma geral da Modelagem baseada em CA-Markov

O processo de modelagem futura da paisagem é retro-alimentado (sistema em feedback) ou seja, a saída ou output é um parâmetro que auxilia na calibração e validação do modelo.

No módulo Markov (Fig. 03) usam-se duas imagens de entrada, e a saída é composta pelas imagens de probabilidade de mudança por tipologia de cobertura do solo, além das matrizes de probabilidade de mudança e de área de transição.

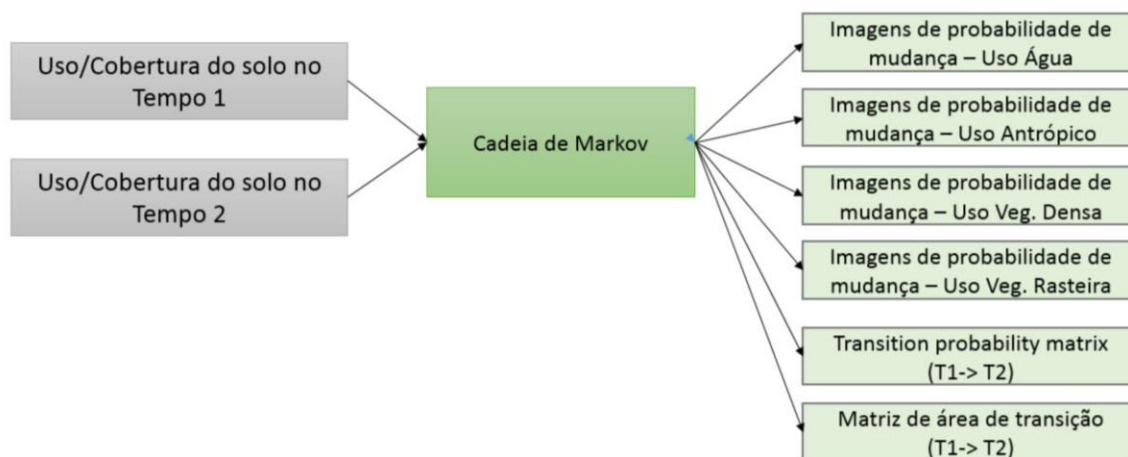


Figura 3: Fluxograma da etapa Cadeia de Markov

Onde:

- Imagem 1 = Mapa de Uso do Solo da Pampulha no ano de 2009
- Imagem 2 = Mapa de Uso do Solo da Pampulha no ano de 2011

O processo de modelagem por Autômato Celular define a probabilidade de mudança do pixel

de acordo com o estado dos vizinhos (filtro de 5X5), e por isso não utiliza a matriz de probabilidade de mudança gerada pelo módulo Markov.

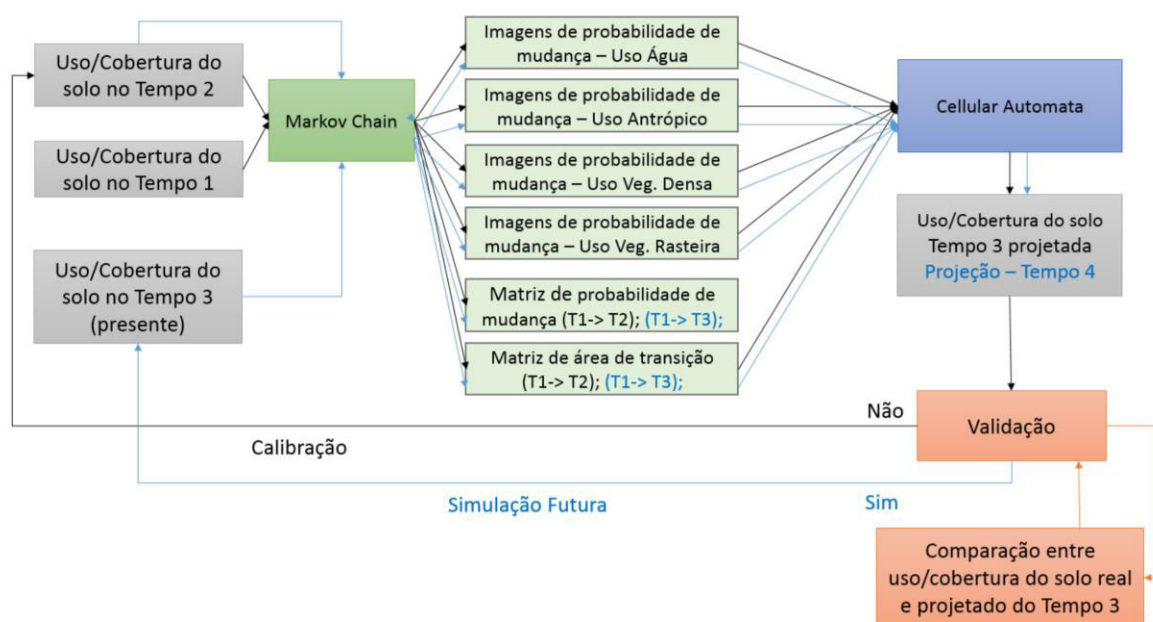


Figura 4: Fluxograma CA-Markov, Calibração, Validação.

Onde:

- Image Time 2 = Mapa de Uso do Solo da Pampulha no ano de 2011
- Image Time 3_Real = Mapa de Uso do Solo da Pampulha no ano de 2013
- Image Time 3_Projetada = Mapa de Uso do Solo da Pampulha projetada para o ano de 2013

O processo de validação do modelo consiste em conferir o quanto o modelo construído consegue realizar as previsões de forma correta. Aconselha-se o uso de um método de validação que aborde os seguintes tópicos:

- Identificar o quanto há de permanência entre os dois mapas: Este fator é importante ser avaliado, já que ao usar imagens com uma variação temporal pequena, ou avaliar uma área de baixa dinâmica espacial, haverá poucas mudanças entre o mapa antigo e o mapa atual;
- O modelo deve ser capaz de avaliar o índice de similaridade entre as mudanças ocorridas, e não apenas a similaridade geral entre mapas: o valor aceitável de validação entre os mapas deve ser calculado considerando as mudanças, e não a similaridade geral, como atualmente é feito pelo índice “*Kappa*” padrão;

Desta forma, uma alternativa ao índice Kappa é o “*Quantity Disagreement*” e o “*Allocation Disagreement*”, propostos por Pontius Jr. e Millones (2011). Os autores definem “*quantity disagreement as the amount of difference between the reference map and a comparison map that is due to the less than perfect match in the proportions of the categories*”, ou seja, quanto maior a diferença entre a quantidade de pixels de uma classe de uso no mapa de referência (mapa real) e no mapa projetado, maior o “*Quantity Disagreement*”.

Pontius Jr. e Millones (2011) definem “*allocation disagreement as the amount of difference between the reference map and a comparison map that is due to the less than optimal match in the spatial allocation of the categories, given the proportions of the categories in the reference and comparison maps*”. Ou seja, quanto maior a diferença na localização dos pixels da classe de um uso no mapa de referência (mapa real) e no mapa projetado, maior o “*Allocation Disagreement*”.

O “*Quantity Disagreement*” e o “*Allocation Disagreement*”, assim como o índice “*Kappa*” padrão apresentam seus resultados numa escala de 0 (zero) a 1 (um), onde quanto mais próximo de um, maior o acerto ou a acurácia do modelo. Desta forma, Pontius Jr. e Millones, (2011) denominam os índices como Kallocation e Kquantity⁸.

Atualmente, é possível calcular o Kallocation e o Kquantity no módulo VALIDADE do Idrisi. Segundo Eastman (2012b), o VALIDATE apresenta o índice Kappa padrão de validação desmembrado em diferentes componentes, cada qual em uma forma especial do Kappa ou por estatística associada baseado no trabalho de Pontius (2000 e 2011).

5. RESULTADOS:

Como resultados deste artigo são apresentados os mapas de uso do solo da Pampulha (Fig. 05), categorizados por tipologia de cobertura do solo: Água (azul), Urbano (Cinza), Vegetação Densa (verde-escuro) e Vegetação Rasteira (verde-amarelado); os mapas de Probabilidade de Mudança condicional da tipologia de Cobertura do Solo (Fig. 06 e 07), a Matriz de probabilidade de transição de áreas calculada por Cadeia de Markov (Tabela 01), os índices de validação do modelo (Fig 08).

⁸ Para maiores informações em como calcular esses índices, ver Pontius e Millones (2011).

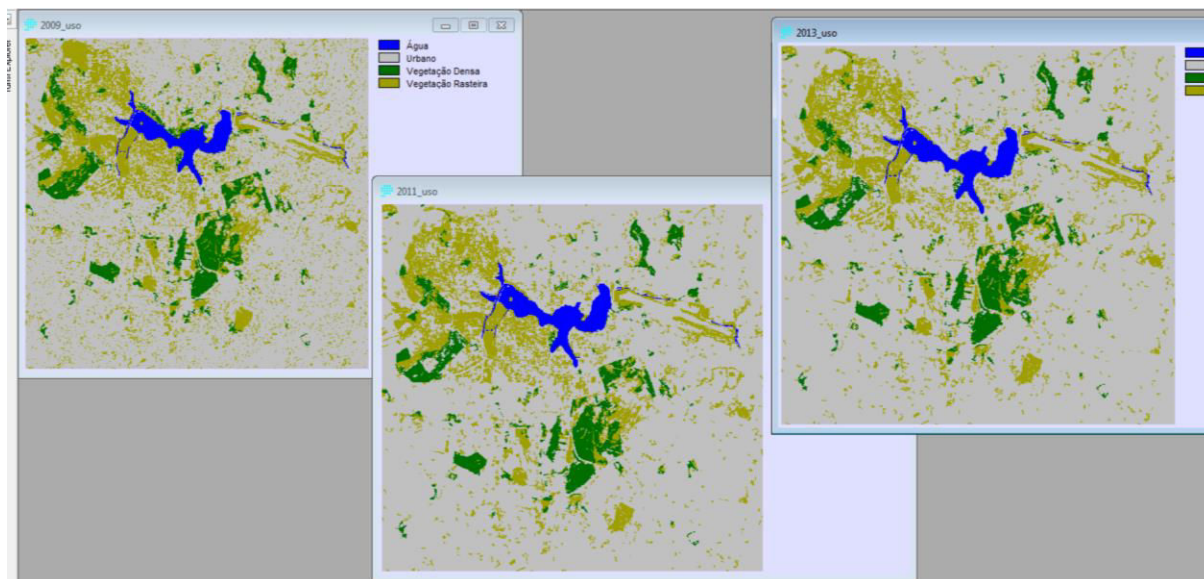


Figura 5: Mapa de cobertura do solo da Regional Pampulha, anos 2009, 2011 e 2013

Como outputs são apresentadas imagens de probabilidade de mudança por categoria de uso (Fig. 06 e 07), que demonstram a potencialidade de alterações da cobertura do solo, especializadas e normalizadas em uma escala de 0 a 1, onde quanto maior o potencial de sofrer alterações, mais próximo de 1 (um) é o valor e no mapa, no exemplo representado por cores quentes.




Figura 6: Probabilidade de Mudança condicional da tipologia de cobertura do solo: Água e Urbano




Figura 7: Probabilidade de Mudança condicional da tipologia de cobertura do solo: Vegetação densa e rasteira

Tabela 2: Matriz de probabilidade de transição de áreas

Expected to transition to :				
	Class 1	Class 2	Class 3	Class 4
Class 1	81542	442	0	0
Class 2	0	2831286	64	0
Class 3	0	17138	170261	15364
Class 4	0	167107	608	342118

Neste trabalho, os índices de validação encontrados estão descritos na Figura 08:

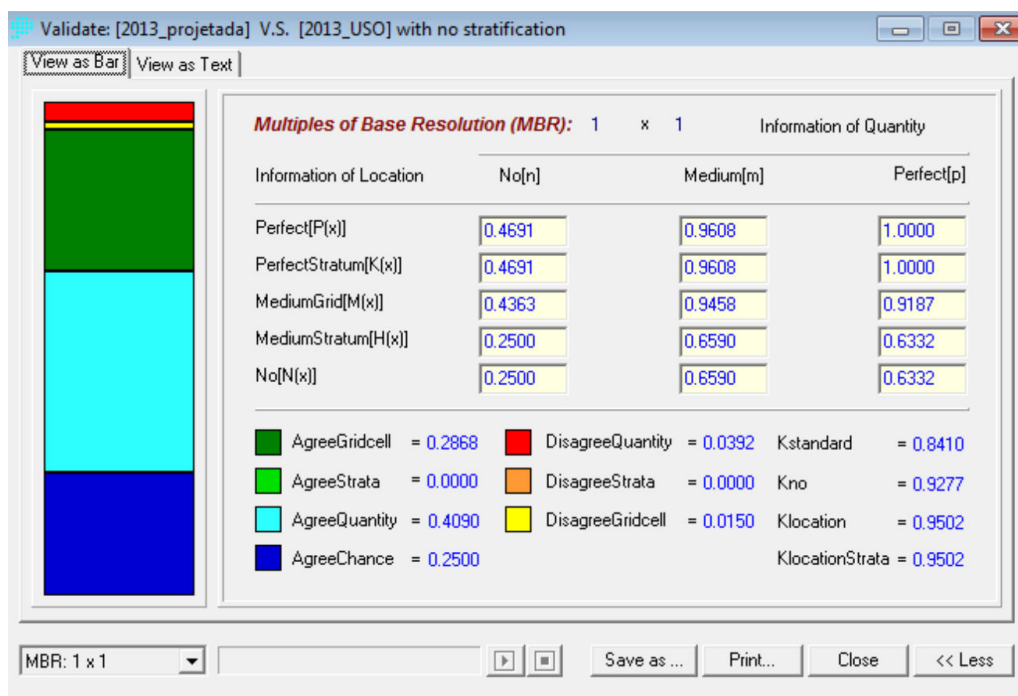


Figura 8: Índices de validação do modelo CA-Markov

6. ANÁLISES

Uma vez validado o modelo, partiu-se então para a projeção da cobertura do solo da Pampulha para o ano de 2020, considerando que haverá continuidade no padrão de alteração na cobertura do solo verificado nos últimos 5 anos (cenário 1), e alterações no padrão de cobertura do solo considerando a implantação de uma nova via de fluxo rápido na regional (cenário 2).

6.1 Cenário 1: A Pampulha em 2020 considerando continuidade das condições de mudança da cobertura do solo, verificadas entre 2009 e 2013.

Na comparação entre os mapas de cobertura do solo de 2013 e 2020 da Regional Pampulha observa-se uma grande perda de Vegetação Rasteira na porção noroeste do mapa, assim como na porção sul da Lagoa da Pampulha (Fig. 09).

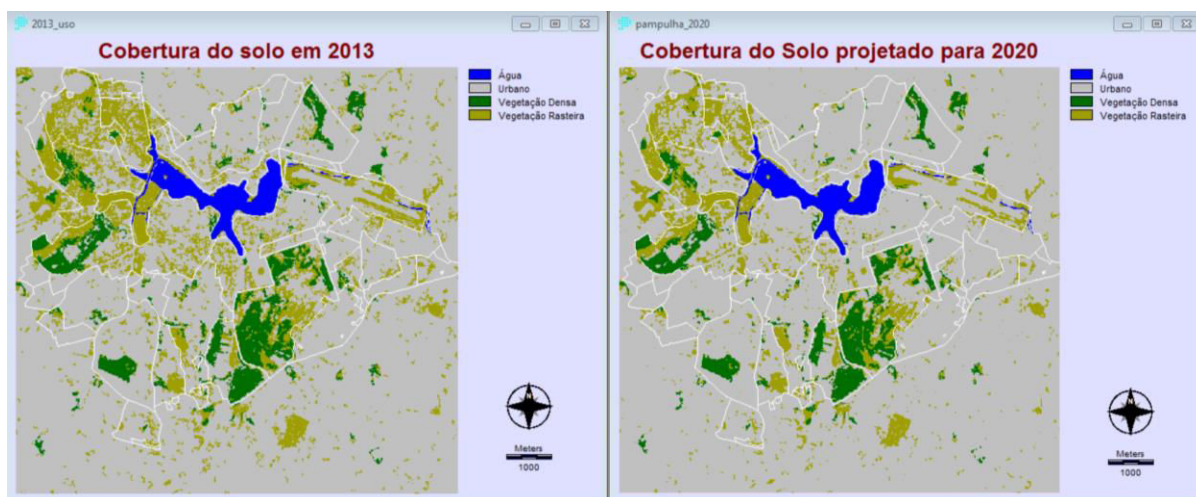


Figura 9: Mapas de uso do solo da Pampulha 2013 real e 2020 projetado

Observa-se ainda a manutenção dos grandes fragmentos de Vegetação Densa, mas a perda dos pequenos fragmentos desta tipologia. Este comportamento na paisagem é explicado pela teoria de Métricas da Paisagem, onde fragmentos maiores apresentam uma área central que reforça o fragmento, tornando-o mais estável na paisagem. (BORGES, Júnia et al, 2010).

A análise visual do mapa é confirmado pela Figura 10, a qual nos mostra que dentre as categorias de cobertura do solo, a que mais aumentou foi a categoria Urbano e a que mais diminuiu foi a categoria Vegetação Rasteira.




Figura10: Gráfico de perdas (roxo) e ganhos (verde) na transformação da cobertura do solo da Regional Pampulha 2013-2020

A análise das mudanças ocorridas exclusivamente no Urbano demonstra que a categoria que mais teve perdas para que esse uso aumentasse foi a Vegetação Rasteira, seguida por Vegetação Densa, em menor quantidade (Fig. 11).




Figura 11: Gráfico de contribuidores para as mudanças na cobertura do solo Urbano

A figura 12a apresenta em verde, de uma forma geral, as localidades que se tornarão urbano em 2020. Uma vez identificado a Vegetação rasteira como a tipologia que mais contribui para a expansão da mancha urbana na Pampulha, optou-se então por aplicar o polinômio de terceira ordem sobre as mudanças que afetam-na, identificando assim a “área core” de transformações desta tipologia (Fig. 12b). Diante disto, verificou-se que a tipologia Urbano vai aumentar principalmente ao redor da Lagoa da Pampulha, sendo que a grande perda de Vegetação Rasteira se dará na região noroeste da Pampulha, abrangendo os bairros: Bandeirantes, Braúnas, Copacabana, Garças, Jardim Atlântico, Lagoa da Pampulha, Santa Amélia, Trevo e Xangrilá.

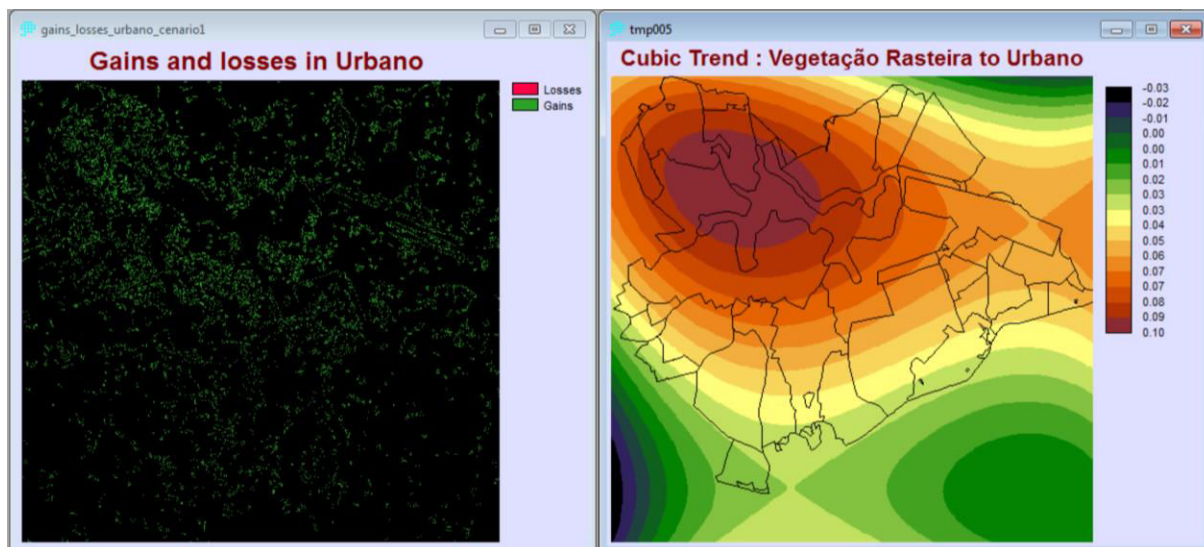


Figura 12: (a) Perdas e ganhos da tipologia Urbano para a Pampulha no ano 2020; (b) área core das transformações na Pampulha – cenário 1

6.2 Cenário 2: A Pampulha em 2020, considerando a implantação de uma nova via de fluxo rápido na regional – o Novo Rodoanel.

A projeção do segundo cenário considerou as imagens de Probabilidade de Mudança condicionais à tipologia de cobertura do solo (Fig 06 e 07), sendo na imagem correspondente ao urbano acrescido do mapa de potencial de transformação da nova via de fluxo rápido a ser implantada na regional Pampulha (Fig. 13a). Como resultado da modelagem, tem-se o mapa projetado da regional para o ano de 2020, como mostrado na figura 13b.

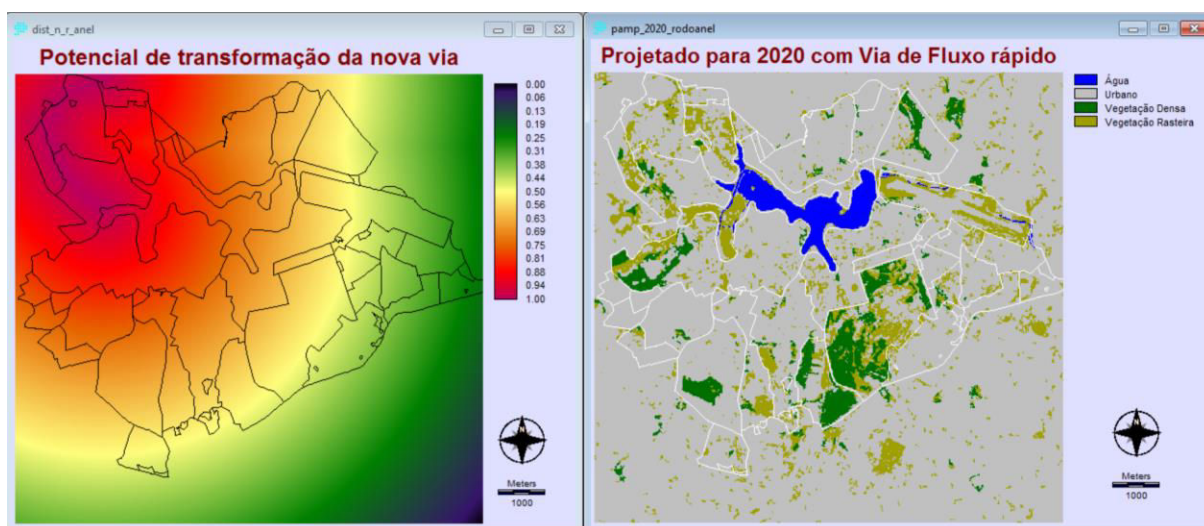


Figura 13a: Potencial de transformação de uma nova via de fluxo rápido na Pampulha

Figura 13b: Pampulha no ano 2020 – cenário 2

O mapa de cobertura do solo do cenário 2 nos mostra uma transformação na regional na porção noroeste ainda maior do que a apresentada no cenário 1. Entretanto no cenário 2, a

transformação está mais concentrada nos bairros Xangrilá, Trevo, Nova Pampulha, Garças e Braúnas.

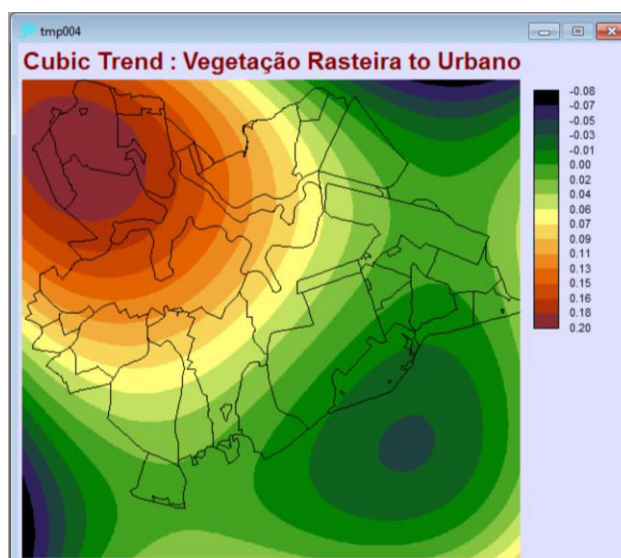


Figura 14: Tendência de mudança através de um algoritmo de 3ª ordem

Observa-se que a área de transformação no segundo cenário é exatamente a mais próxima à de implantação da nova rodovia, a qual concentrará as transformações nesta região.

6.3 Análise da região de maior transformação em ambos os cenários

Ambos os cenários mostram que o aumento da mancha urbana se dará através da perda de vegetação rasteira, predominantemente. Mostram também que há uma maior concentração das mudanças previstas para a área noroeste da Pampulha.

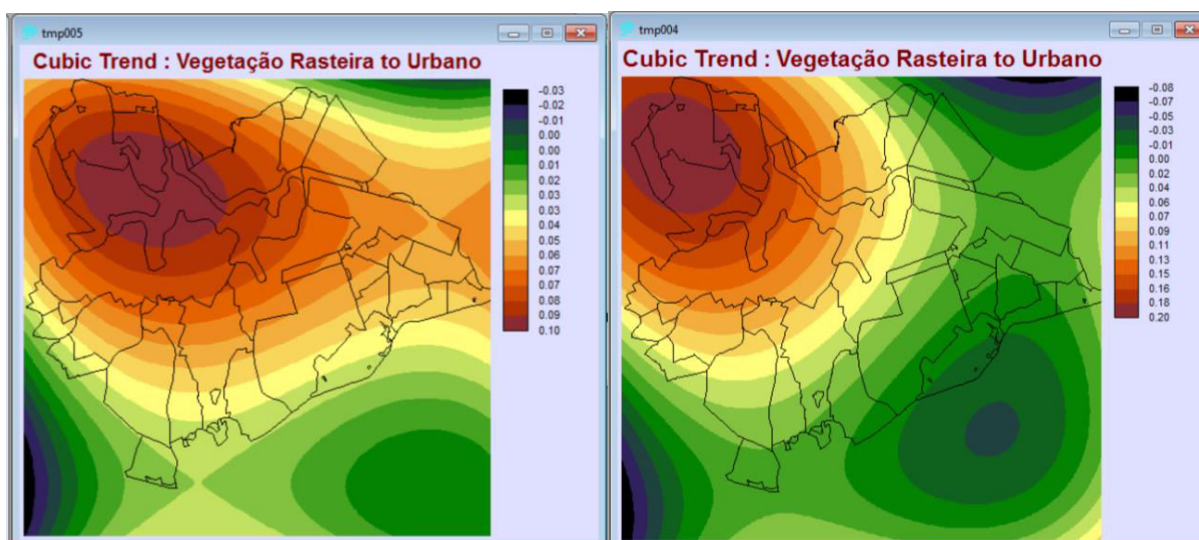


Figura 15: (a) área core das mudanças cenário 1 (b) área core das mudanças cenário 2

Ao comparar ambos os cenários com o mapa de zoneamento da Pampulha (Fig. 16), observa-se uma maior tendência do aumento da mancha urbana predominantemente em área de zoneamento definido como Zona de Proteção 1 e 2 (ZP-1 e ZP-2). Estas regiões, no caso da Pampulha, são destinadas à proteção ambiental e preservação do patrimônio histórico, cultural, arqueológico ou paisagístico. Consequentemente, são áreas de menor disponibilidade na oferta de serviços de infraestrutura básica como esgoto e água.

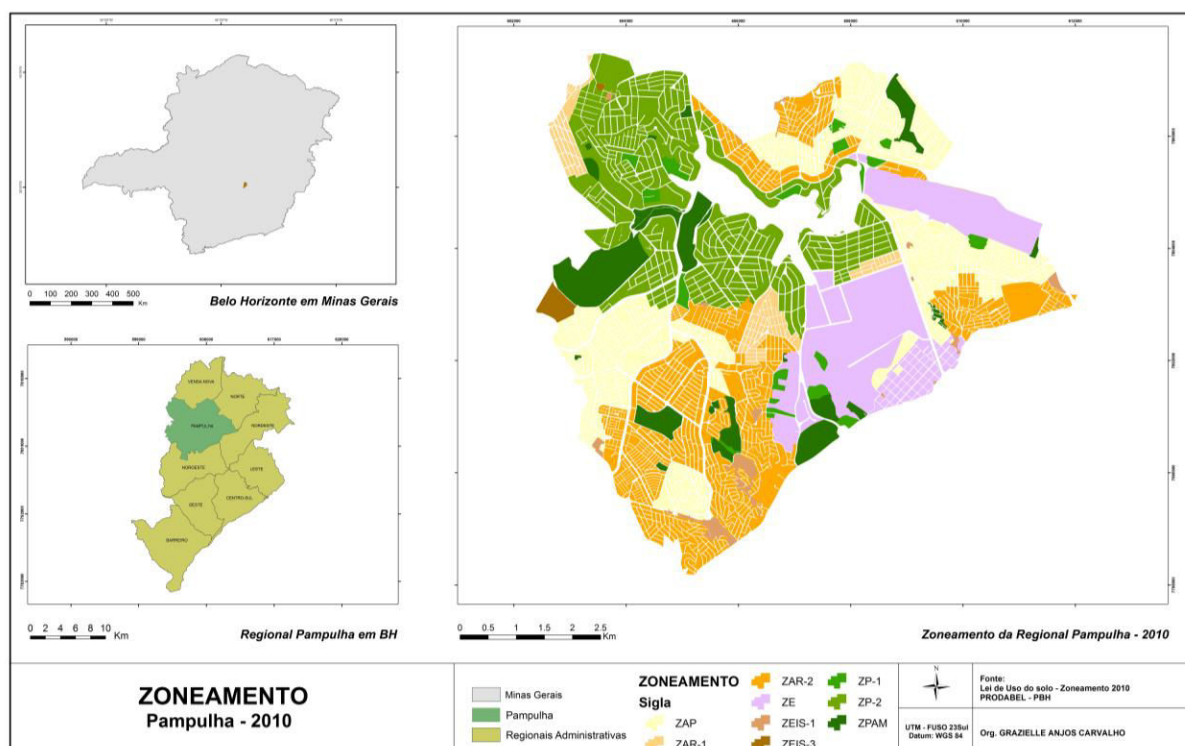


Figura16: Zoneamento Urbanístico da Pampulha – Belo Horizonte - 2010

Esta região também é caracterizada por baixa disponibilidade de centros comerciais e serviços, como pode ser visualizado na Figura 17.

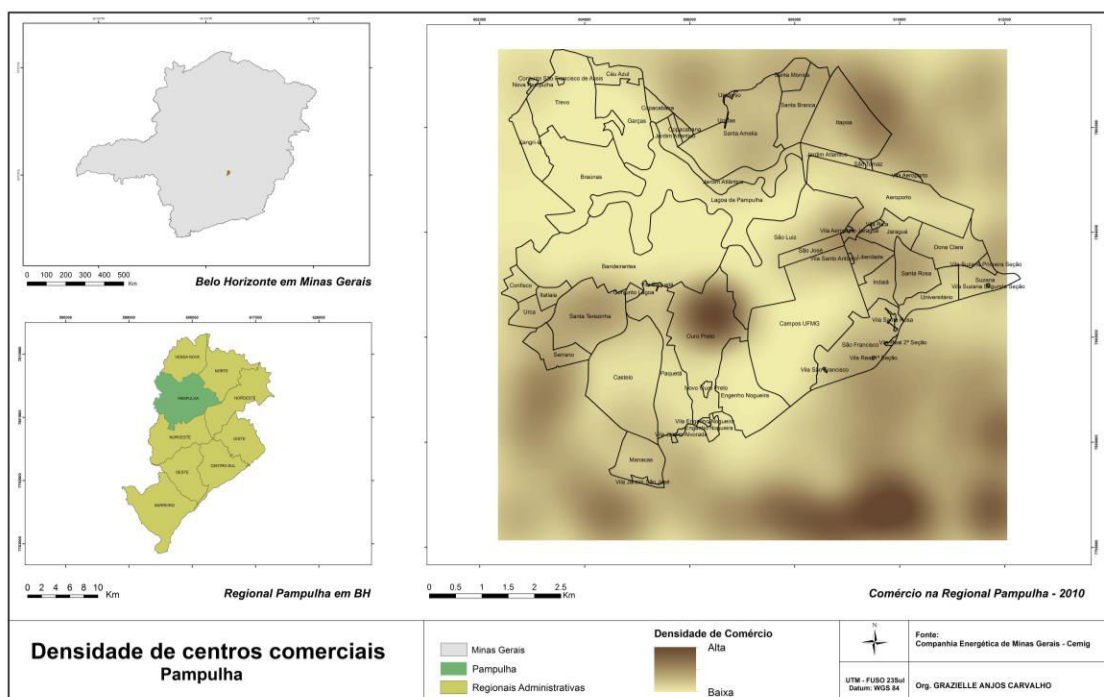


Figura 17: Densidade de centros comerciais na Pampulha – Belo Horizonte

Já a Figura 18 nos mostra que a Região Noroeste, identificada como a região de maior transformação na cobertura do solo da regional Pampulha, dispõe de espaços que permitirão essa transformação, tais como lotes vagos e residências de até 1 andar, que poderiam ser substituídos por novos empreendimentos imobiliários.

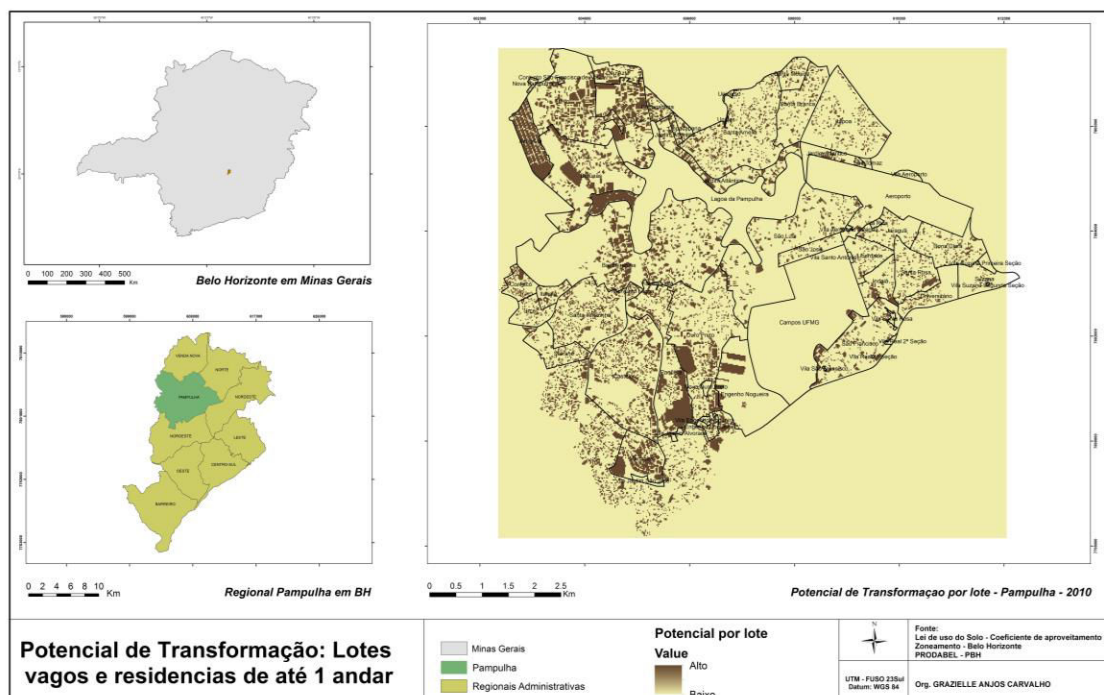


Figura 18: Potencial de transformação segundo a disponibilidade de lotes vagos e residências de até 1 andar na Pampulha

7. CONSIDERAÇÕES FINAIS

A modelagem de possíveis mudanças na Pampulha foi realizada considerando dois cenários: a continuidade do padrão de transformação da paisagem verificado nos últimos 5 anos; e as transformações decorrentes da implantação de uma nova via na regional. Em ambas as simulações os resultados mostraram que a porção noroeste da regional apresenta-se como a que mais necessitará de atenção pelos gestores.

O fato desta área ter um zoneamento restritivo ao uso, mas ainda apresentar um elevado potencial de transformação considerando o coeficiente de aproveitamento por lote, mostra que os resultados apresentados na modelagem podem vir a se tornar realidade, o que demandaria ações preventivas para garantir ou não que estes cenários aconteçam. Caso seja de interesse dos gestores o desenvolvimento sustentável da região noroeste da Pampulha, estes devem tomar medidas que aumentem a oferta de infraestrutura básica na localidade, assim como serviços e comércios imediatamente, para que o processo de crescimento da mancha urbana nesta área não se dê de forma a sobrecarregar a infraestrutura existente.

Desta forma, o presente artigo demonstra que o uso de Modelos de Simulação podem ser um instrumento extremamente eficaz de apoio às rotinas de planejamento urbano. E que apesar dos resultados aqui apresentados apresentarem-se com apenas quatro tipologias de cobertura do solo, foi possível identificar as tendências de forma satisfatória.

O investimento em dados de melhor qualidade cartográfica (escala, temporalidade) se faz necessário uma vez que auxiliará no processo de planejamento das nossas cidades com maior precisão e complexidade nos Modelos de Simulação atualmente disponíveis.

REFERÊNCIAS:

- ALMEIDA, C. M. **Modelagem da dinâmica espacial como uma ferramenta auxiliar ao planejamento: simulação de mudanças de uso da terra em áreas urbanas para as cidades de Bauru e Piracicaba (SP)** / C. M. Almeida. – São José dos Campos: INPE, 2003. 351p. – (INPE-10567-TDI/942/A). Acessado em 04/03/2013. Disponível em: http://www.dsr.inpe.br/geu/Teses%20de%20Doutorado/Tese_Claudia_Almeida.pdf
- BATTY, Michael; XIE, Yichun; SUN, Zhanli. **Modeling urban dynamics through GIS-based cellular automata**. Computers, environment and urban systems, v. 23, n. 3, p. 205-233, 1999.
- BORGES, J., CARVALHO, G., MOURA, A. C. M., & NASCIMENTO, J. **Estudo da conformação da paisagem de Sabará-MG para compreensão das métricas do fragstats em padrões de uso do solo**. In: Congresso Brasileiro de Cartografia. 2010. p. 1473-1481.

BURROUGH, P. **Dynamic Modelling And Geocomputation**. In: P. Longley, M. Batty and R. McDonnel. *Geocomputation: A Primer*. London, John Wiley & Sons. 1998.

CÂMARA, A. S. **Spatial Simulation Modelling**. In: M. Fisher. *Spatial Analytical Perspectives on GIS*. London, Taylor & Francis. 1996, pg. 213-218.

COUCLELIS, H. **Cellular worlds: a framework for modelling micro-macro dynamics**. *Environment and Planning A*, 17, 585-596, 1985.

COUCLELIS, H. **From Cellular Automata to Urban Models: New Principles for Model Development and Implementation**. *Environment and Planning B: Planning and Design* 24: (1997). 165-174.

DE ALMEIDA, Cláudia Maria; CÂMARA, Gilberto; MONTEIRO, Antonio Miguel Vieira. **Geoinformação em urbanismo: cidade real× cidade virtual**. Oficina de Textos, 2007.

DIMURO, Graçaliz P. et al. **Modelos de Markov e Aplicações**. VI Oficina de Inteligência Artificial, Pelotas: Educat, p. 37-59, 2002.

EL YACOUBI, Samira; CHOPARD, Bastien; BANDINI, Stafania (Ed.). **Cellular Automata: 7th International Conference on Cellular Automata for Research and Industry, ACRI 2006**, Perpignan, France, September 20-23, 2006, Proceedings. Springer, 2006.

ENGELLEN, Guy et al. **Using cellular automata for integrated modelling of socio-environmental systems**. *Environmental monitoring and Assessment*, v. 34, n. 2, p. 203-214, 1995.

FUGLSANG, Morten; MÜNIER, Bernd; HANSEN, Henning Sten. **Modelling land-use effects of future urbanization using cellular automata: An Eastern Danish case**. *Environmental Modelling & Software*, v. 50, p. 1-11, 2013.

FURTADO, Bernardo Alves; VAN DELDEN, Hedwig. **Modelagem urbana e regional com autômatos celulares e agentes: panorama teórico, aplicações e política pública**. 2011. Instituto de Pesquisas Econômica e aplicada - IPEA . Acessado em março de 2013. Disponível em: http://www.ipea.gov.br/sites/000/2/publicacoes/tds/td2_1576_Web.pdf

GEOGRAPHICAL SCIENCES COMMITTEE et al. **Advancing Land Change Modeling: Opportunities and Research Requirements**. National Academies Press, 2014.

KAMUSOKO, Courage et al. **Rural sustainability under threat in Zimbabwe—simulation of future land use/cover changes in the Bindura district based on the Markov-cellular automata model**. *Applied Geography*, v. 29, n. 3, p. 435-447, 2009.

LIMA, EDGAR BARBOSA. **Modelos microscópicos para simulação do tráfego baseados em autômatos celulares**. 2007. Tese de Doutorado. Master's thesis, Universidade Federal Fluminense.

MARIA DE ALMEIDA, Cláudia et al. **Stochastic cellular automata modeling of urban land use dynamics: empirical development and estimation**. Computers, Environment and Urban Systems, v. 27, n. 5, p. 481-509, 2003.

MACEDO, Rodrigo de Campos, et al. **Modelagem dinâmica espacial das alterações de cobertura e uso da terra relacionadas à expansão canavieira**. Bol. Ciênc. Geod., sec. Artigos, v. 19, n. 2, p. 313-337, 2013.

MELOTTI, Gledson. **Aplicação de Autômatos Celulares em Sistemas Complexos: Um Estudo de Caso em Espalhamento de Epidemias**. 2009. Tese de Doutorado. Universidade Federal de Minas Gerais.

MEMARIAN, Hadi et al. **Validation of CA-Markov for simulation of land use and cover change in the Langat Basin, Malaysia**. Journal of Geographic Information System, v. 4, p. 542, 2012.

MITSOVA, Diana; SHUSTER, William; WANG, Xinhao. **A cellular automata model of land cover change to integrate urban growth with open space conservation**. Landscape and Urban Planning, v. 99, n. 2, p. 141-153, 2011.

O'SULLIVAN, David; TORRENS, Paul M. **Cellular models of urban systems**. In: Theory and Practical Issues on Cellular Automata. Springer London, 2001. p. 108-116.

ONSTED, Jeffrey A.; CHOWDHURY, Rinku Roy. **Does zoning matter? A comparative analysis of landscape change in Redland, Florida using cellular automata**. Landscape and Urban Planning, v. 121, p. 1-18, 2014.

PERES, O. M. & POLIDORI, M. C. **Modelos Urbanos baseados em Autômatos Celulares: integrando ambiente natural e o crescimento urbano**. 2009. Acessado em 04/03/2013, às 15:26 horas. Disponível em: <http://www.lbd.dcc.ufmg.br/colecoes/wcama/2009/010.pdf>

PONTIUS, R.G. **Quantification error versus location error in comparison of categorical maps**. Photogrammetric Engineering & Remote Sensing, 66(8): 1011-1016, 2000.

PONTIUS JR, Robert Gilmore et al. **Comparing the input, output, and validation maps for several models of land change**. The Annals of Regional Science, v. 42, n. 1, p. 11-37, 2008.

PONTIUS JR, Robert Gilmore & MILLONES, Marco. **Death to Kappa: birth of quantity disagreement and allocation disagreement for accuracy assessment**, International Journal of Remote Sensing, 32:15, 4407-4429; 2011.

PREFEITURA DE BELO HORIZONTE. **Pampulha: modernização urbanística acelerada**. 200-. Acessado em Janeiro de 2015. Disponível em: <http://portalpbh.pbh.gov.br/pbh/>

ROY, Geoffrey G.; SNICKARS, Folke. **City life; a study of cellular automata in Urban Dynamics**. Spatial Analytical Perspectives and GIS, Taylor and Francis, London, p. 213-229, 1996.

SASSO, Juliana Bonás; CHIMARA, Henrique Dal Bo; MONTEIRO, Luiz Henrique Alves. **Epidemias e modelos epidemiológicos baseados em autômatos celulares: uma breve revisão.** Cad. de Pós-Graduação em Eng. Elétrica, v. 4, n. 1, p. 71-8, 2004.

SOARES FILHO, Britaldo Silveira. **Modelagem da dinâmica de paisagem de uma região de fronteira de colonização amazônica.** 1998. Tese de Doutorado. Universidade de São Paulo.

SOARES-FILHO, Britaldo Silveira, et al. **Modelagem de dinâmica de paisagem: concepção e potencial de aplicação de modelos de simulação baseados em autômato celular.** Ferramentas para modelagem da distribuição de espécies em ambientes tropicais. Belém (disponível em www.csr.ufmg.br/dinamica), 2003.

SUN, Jian et al. **CA-Based Urban Land Use Prediction Model: A Case Study on Orange County, Florida, US.** Journal of Transportation Systems Engineering and Information Technology, v. 12, n. 6, p. 85-92, 2012.

TOBLER, W. **Cellular Geography.** In GALE, S. & OLSSSEN, G. (Eds.) Philosophy in Geography. Dordrecht, Reidel, 1979.

UMBELINO, G. BARBIERI, A. **Uso de Autômatos Celulares em estudos de população, espaço e ambiente.** XVII Encontro Nacional de Estudos Populacionais – ABEP – Caxambu – 20 a 24 de Setembro de 2010. Acessado em 04/03/2013, às 15:45 horas. Disponível em: http://www.abep.nepo.unicamp.br/encontro2010/docs_pdf/eixo_2/abep2010_2432.pdf

UMBELINO, G. J.M. **Simulações de distribuição espacial domiciliar e projeções demográficas intraurbanas com apoio de geotecnologias.** 2012. Tese de Doutorado - Universidade Federal de Minas Gerais, Programa de Pós Graduação em Demografia, Belo Horizonte, 2012.

VERSTEGEN, Judith A. et al. **Identifying a land use change cellular automaton by Bayesian data assimilation.** Environmental Modelling & Software, v. 53, p. 121-136, 2014.

WHITE R; ENGELEN G. **Cellular automata as the basis of integrated dynamic regional modeling.** Environment and Planning B: Planning and Design, 1997, 24(2): 235–246.

XIMENES, A. de C. et al. **Modelagem Dinâmica do desmatamento na Amazônia.** Boletim de Ciências Geodésicas, v. 14, n. 3, p. 370-391, 2008.

Artigo 04: Comparação dos métodos “*What if / If then*” por Autômato Celular e Redes Neurais: simulação de cenários futuros da Regional Pampulha considerando a implantação de uma nova via de fluxo rápido

Comparação dos métodos “*What if / If then*” por Cadeia de Markov, Autômato Celular e Redes Neurais: simulação de cenários futuros da Regional Pampulha considerando a implantação de uma nova via de fluxo rápido

Carvalho, G.A.^{1,2*}, Moura, A.C.M.²

¹Geoscience College, Geography Department, Federal University of Minas Gerais, 31270-901, Pampulha – Belo Horizonte, Minas Gerais, Brazil

²GIS Laboratory, Architecture College, Urban Planning Department, Federal University of Minas Gerais, Federal University of Minas Gerais, 30130-140, Savassi – Belo Horizonte, Minas Gerais, Brazil

*Corresponding author: E-mail: grazielleac@ufmg.br, Tel +55 31 3409-8827

Resumo:

A rotina de planejamento estratégico ou Métodos *What if/If then* é toda e qualquer ação que vise simular em ambiente computacional ações de intervenção no território compostas por projetos e decisões políticas ainda não aprovados e/ou implementados no espaço. Este artigo tem por objetivo comparar as ferramentas CA-MARKOV e LCM, ambas disponíveis no software IDRISI/SELVA na elaboração de uma rotina de planejamento estratégico através da simulação da implantação de uma via de fluxo rápido da Regional Pampulha para o ano de 2020. Os Modelos de Simulação são baseados em Autômato Celular, Cadeia de Markov e Redes Neurais. Como a lógica empregada na localização das mudanças em Autômatos Celulares (vizinho mais próximo) é diferente da lógica empregada por Redes Neurais (redes), o resultado do cenário simulado para a Regional Pampulha considerando a implantação de uma via de fluxo rápido são diferentes. Não obstante, ambos os cenários apontam a borda noroeste da Lagoa da Pampulha como a mais propícia às mudanças. O objetivo é comparar os modos de aplicação e os resultados obtidos com ambos os modelos, uma vez que ambos se destinam à ação preditiva, e analisar o quanto a escolha do método empregado pode influenciar no processo de tomada de decisão. O que se destaca é que há a necessidade de conhecer plenamente o objeto de estudo e a forma como este se comporta, para que através de avaliação de resultados obtidos o modelo seja o melhor retrato da realidade analisada, o que dá bases para a escolha pelo método mais correto para aquela determinada situação.

Palavras Chaves: What if/If Then, Autômato Celular, Redes Neurais, modelo de mudança, cenários

1. INTRODUÇÃO

A rotina de planejamento estratégico ou Métodos *What if/If then* é toda e qualquer ação que vise simular em ambiente computacional projetos e decisões políticas ainda não aprovados e/ou implementados no espaço. Soma-se a este o fato da apresentação dos resultados obtidos serem ancorados na comunicação/visualização do conteúdo essencial de uma forma fácil e acessível aos diferentes públicos envolvidos no processo de planejamento (HARRIS, 1989; HOPKINS, 1999; BRAIL e KLOSTERMAN, 2001).

O uso de rotinas de planejamento estratégico é necessário uma vez que Sistemas de Suporte ao Planejamento (PSS) são desenvolvidos como sistemas integrados aptos para lidarem com uma diversa gama de atividades que incluem: planejamento abrangente; alocação de crescimento; planejamento de esboço (*sketch planning processes*); planejamento ambiental; modelagem integrada do uso e transporte (*integrated land use-transportation modelling*); modelos de simulação de normativas relacionadas ao uso do solo (*land-use policy simulation models*); visualização de desenho urbano (*urban design*); comunicação do projeto urbano entre planejadores e tomadores de decisões (*communicating urban design to planners and decision makers*); exploração de cenários alternativos com base em classificação e ponderação de pesos de indicadores; planejamento comunitário; gestão de dados, análise, resolução de problemas, design, tomada de decisão e atividades de comunicação (BRAIL e KLOSTERMAN, 2001; ZYNGIER, et al. 2014).

Segundo Brail e Klosterman (2001), “*a scenario is not a prediction, but rather it is an illustration of contingent events likely to occur if key assumptions come to fruition*”. Para se executar uma rotina de planejamento estratégico e simular um cenário, é necessário estruturar o Modelo de Simulação para que este seja capaz de identificar as regras de transição, a partir das quais serão feitas previsões das mudanças no uso/cobertura do solo. Para tal, o Modelo de Simulação passa pelas etapas de calibração e validação, e só após elas é possível simular os cenários de planejamento estratégico.

A pergunta “E se...?” corresponde a um cenário passível de ser simulado em ambiente computacional. Este artigo tem por objetivo comparar as ferramentas CA-MARKOV e LCM, ambas disponíveis no software IDRISI/SELVA na elaboração de uma rotina de planejamento estratégico através da simulação da implantação de uma via de fluxo rápido da Regional Pampulha para o ano de 2020.

2. MATERIAS E MÉTODOS

Os Modelos de Simulação da paisagem apresentam como dados básicos essenciais o mapeamento do uso ou da cobertura do solo e as variáveis explicativas do objeto de estudo. Como pré-requisitos iniciais ao processo de modelagem, os dados foram configurados considerando a padronização do sistema de projeção (SIRGAS 2000, fuso 23S); do formato matricial, com mesmo retângulo envolvente, resolução espacial (5mX5m), escala de normalização do potencial de transformação (0 a 1) do tipo numérico contínuo. Cabe ressaltar que embora as variáveis iniciais sejam categóricas (a existência de um determinado

uso/cobertura a partir da imagem ou a existência de uma ação de intervenção urbana como uma via projetada), foram produzidos mapas *rasters* com valores contínuos sobre o potencial de transformação do território para um determinado uso ou a partir de um elemento proposto para o território.

Como input dos Modelos de Simulação utilizaram-se imagens Rapid Eye para elaborar:

- Mapa de cobertura do solo da Pampulha – ano de 2009
- Mapa de cobertura do solo da Pampulha – ano de 2011
- Mapa de cobertura do solo da Pampulha – ano de 2013

As variáveis *drivers* ou explicativas selecionadas por análise fatorial para compor o Modelo de Simulação foram:

Tabela 1: Relação das bases cartográficas utilizadas no artigo⁹

Camada	Fonte
Potencial de transformação por distância das Operações Urbana	Shapefile das Operações Urbanas cedida pela PBH
Densidade de Comércio	Shapefile de Postes da Cemig: atributo informando o uso dado à energia elétrica
Potencial de transformação do Zoneamento	Shapefile do Zoneamento Urbanístico, cedida pela PBH
Acessibilidade e Capilaridade	Shapefile das Tipologias de vias, cedida pela PBH
Densidade de projetos aprovados na PBH	Shapefile dos projetos aprovados na PBH, cedida pela PBH
Potencial de transformação da vegetação densa	Matriz de probabilidade de Mudança por Cadeia de Markov calculada a partir dos mapas de cobertura do solo de 2009 e 2011 – Fonte – Imagens RapidEye, IEF e Lab de Geoprocessamento da EA
Potencial de transformação da vegetação rasteira	Matriz de probabilidade de Mudança por Cadeia de Markov calculada a partir dos mapas de cobertura do solo de 2009 e 2011 – Fonte – Imagens RapidEye, IEF e Lab de Geoprocessamento da EA

A variável de planejamento estratégico para gerar o cenário foi:

- Mapa de Potencial de transformação da nova via de fluxo rápido a ser implantada na Regional Pampulha (Fig.1), onde quanto mais próximo da nova via, maior o potencial de transformação.

⁹ Para maiores detalhes sobre as bases cartográficas, vide o artigo 1 “*Comparação entre métodos de análise multivariada na seleção de variáveis explicativas para compor um Modelo de Mudança da Paisagem – Aplicações na Pampulha, Brazil*”.

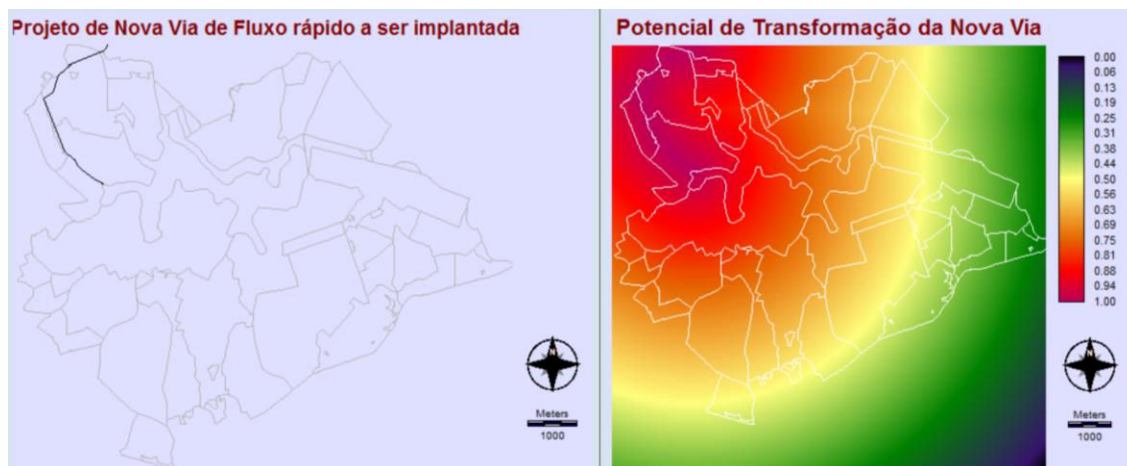


Figura 1: (a) Projeto de implantação de uma nova via de Fluxo rápido (b) Potencial de transformação da nova via de fluxo rápido a ser implantada na Regional Pampulha.

O processo de validação do modelo consiste em conferir o quanto o modelo construído consegue realizar as previsões de forma correta. Pontius e Millones (2011) aconselham a aplicação de um método de validação que aborde os seguintes tópicos:

- Identificar o quanto há de permanência entre os dois mapas: Este fator é importante ser avaliado, já que ao usar imagens com uma variação temporal pequena, ou avaliar uma área de baixa dinâmica espacial, haverá poucas mudanças entre o mapa antigo e o mapa atual;
- O modelo deve ser capaz de avaliar o índice de similaridade entre as mudanças ocorridas, e não apenas a similaridade geral entre mapas: o valor aceitável de validação entre os mapas deve ser calculado considerando as mudanças, e não a similaridade geral, como atualmente é feito pelo índice “Kappa” padrão;

Desta forma, para fazer a validação dos modelos utilizou-se o módulo “Validade”, disponível no IDRISI/Selva, que segue os preceitos estipulados pelos autores (PONTIUS e MILLONES, 2011).

2.1 Modelo de Simulação baseado em Cadeia de Markov e Autômato Celular

A organização do modelo de projeção da cobertura do solo da Pampulha foi realizado com o emprego do IDRISI, através da ferramenta CA-MARKOV. Os fluxogramas (Fig. 02, 03 e 04) descrevem as etapas deste processo na modelagem. O processo de modelagem futura da paisagem é retroalimentado (sistema em *feedback*) ou seja, a saída ou output é um parâmetro que auxilia na calibração e validação do modelo. O fluxograma geral (Fig. 02) demonstra que

o processo é realizado no mínimo duas vezes: na etapa de calibração/validação do modelo; e na etapa de projeção e/ou simulação futura.

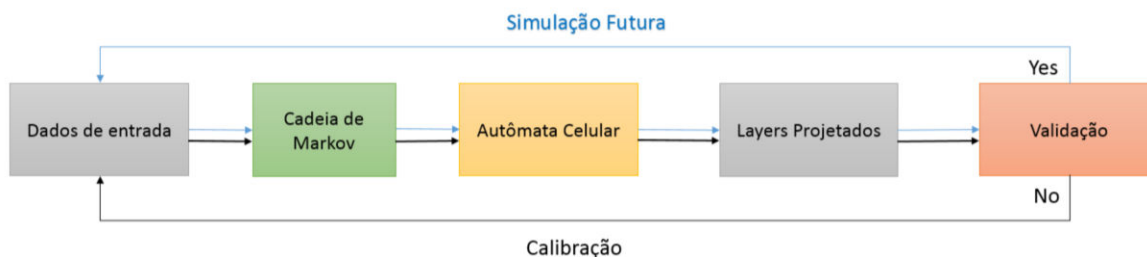


Figura 2: Fluxograma geral da Modelagem baseada em CA-Markov

Segundo Eastman (2012), no módulo Markov (Fig. 03) usam-se em todo o processo o total de três diferentes mapas de cobertura do solo e a saída é composta pelas imagens de probabilidade de mudança por tipologia de cobertura do solo, além das matrizes de probabilidade de mudança e de área de transição. As imagens de probabilidade de mudança por tipologia de cobertura do solo demonstram a potencialidade de alterações da cobertura do solo, espacializadas e normalizadas em uma escala de 0 a 1, aonde quanto mais próximo de 1 (um) maior é o potencial de transformação.

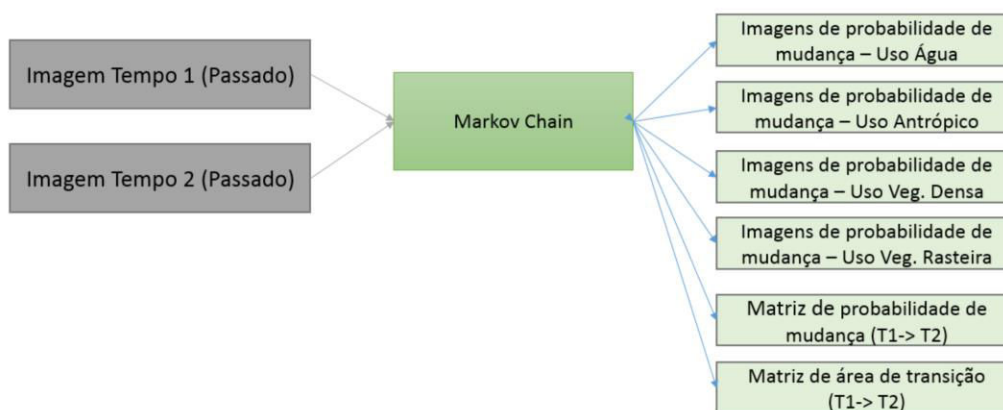


Figura 3: Fluxograma da etapa Cadeia de Markov

O processo de modelagem por Autômato Celular (Fig. 04) define a probabilidade de mudança do pixel de acordo com o estado dos vizinhos (filtro de 5x5) e por isso não utiliza a matriz de probabilidade de mudança gerada pelo módulo Markov. O *output* desta etapa é a imagem projetada que será validada na primeira rodada.

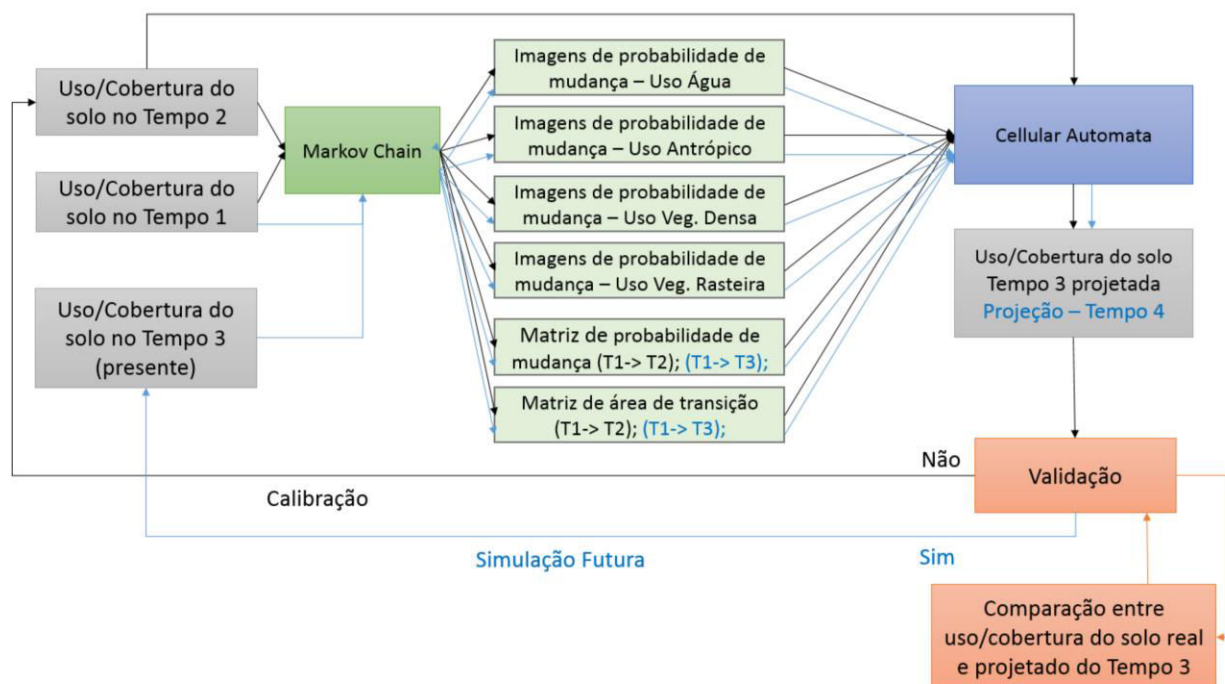


Figura 4: Fluxograma da etapa Autômato Celular, Calibração, Validação

Uma vez validado o modelo de projeção, por álgebra de mapas, acrescentou-se o mapa de “Potencial de Transformação da nova via de fluxo rápido” ao mapa de “Probabilidade de Transformação da Cobertura do Solo de Urbano”. O *output* da segunda rodada na etapa Autômato Celular é o cenário simulado para o ano de 2020 a partir do impacto da nova via implantada (Fig. 07).

2.2 Modelo de Simulação baseado em Redes Neurais e Cadeia de Markov

Segundo Eastman (2012), para usar o Land Change Model (LCM), assim como o CA-Markov, é necessário ter como input 03 (três) imagens de uso do solo, todas atendendo os parâmetros mencionados anteriormente. Para melhor entendimento do processo, propõe-se considerar que T1 é imagem mais antiga, T2 é a imagem intermediária e T3 é a imagem recente.

O *Change Analysis* apresenta uma série de gráficos que ajudam a compreender o comportamento das mudanças por tipologia de uso/cobertura, além de apresentar os mapas das mudanças e permanência.

No *Transition Model* foi criado o “Submodelo de Transição” indicando todas as transformações na paisagem detectadas no intervalo de tempo T1 -> T2, considerando como um dos *inputs* o mapa de mudanças e permanências, *output* do *Change Analysis*. É ainda no *Transition Model* que são inseridas as Variáveis *Drivers* no modelo de mudança, usadas para

responder pelos processos de mudança nas tipologias de uso/cobertura do solo. Essas variáveis devem ter sido anteriormente selecionadas em processo robusto, como apresentado no conjunto da tese a escolha baseada em análise fatorial, o método que melhor deu resultado para este tipo de investigação, e infoma-se se estas apresentam comportamento estático ou dinâmico.

Ao aplicar o modelo seleciona-se o método *MLP (Multi-Layer Perceptron neural network classifier)*, baseado em redes neurais para identificar as regras de transição da paisagem verificadas na área de estudo e então calcular o potencial de transição.

Vale considerar que Redes Neurais Artificiais (RNA) é um método de aprendizagem (*Learning Machine*) e processamento automático inspirado no modelo biológico do cérebro, o qual tenta reproduzir seu comportamento no processo de aprendizagem. Os processos entre variáveis acontecem de forma ponderada por um algoritmo que se ajusta iterativamente. De uma forma geral, pode-se afirmar que as Redes Neurais Artificiais buscam identificar e reprojeter as conexões existentes entre as camadas de informação a serem avaliadas, e que este aprendizado por rede é usado para definir as regras de transição para se projetar o cenário futuro. (ATKINSON e TATNALL, 1997; CHAN et al., 2001; CIVCO, 1993; HSIEH, 2009; KARUL e SOYUPAK, 2006; GENARO et al., 2010; GEOGRAPHICAL SCIENCES COMMITTEE, 2014).

Como resultado do *Transition Model* são produzidos os mapas de potencial de transformação por categoria de análise.

Change Analysis, Model Training, and Validation

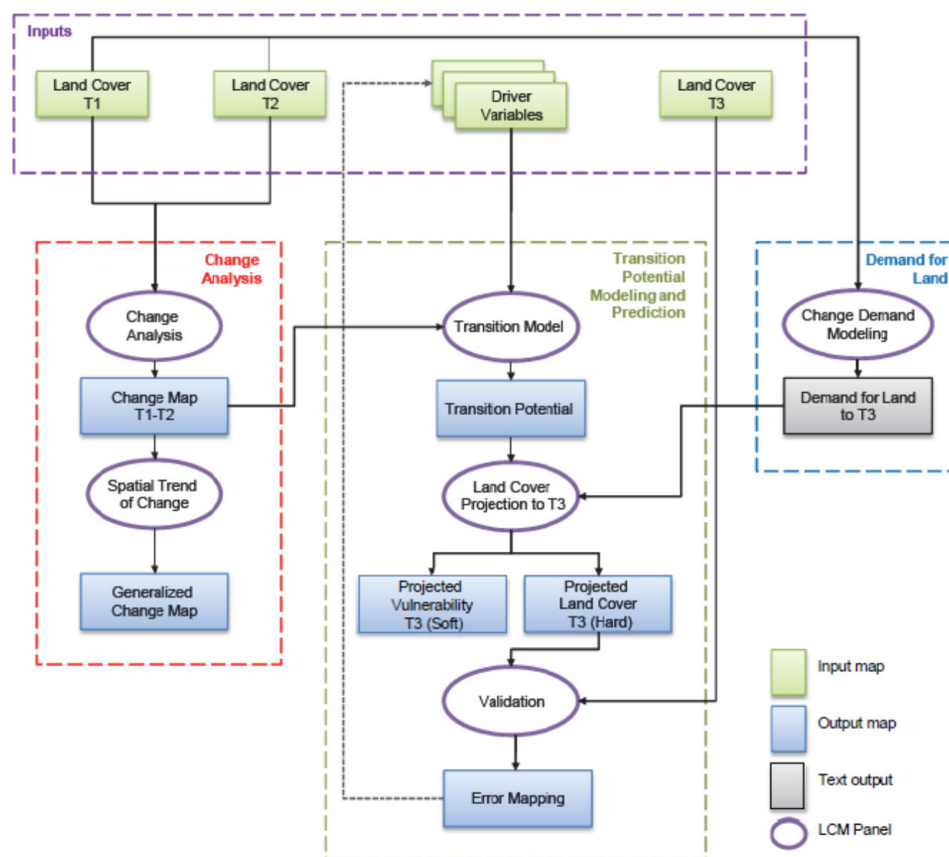


Figura 5: Fluxograma do processo de Análise de Mudanças, Modelos de treinamento e Validação no LCM. Adaptado de (Eastman, J. R. 2012b)

A etapa seguinte no processo de modelagem da paisagem é a projeção do mapa T3_projetado. Enquanto as regras de transição foram definidas por Redes Neurais, a quantidade de pixels que sofrerão transformações é definido por Cadeia de Markov. O mapa T3_projetado foi comparado com o mapa T3_real e verificado o percentual de acerto superior a 94%, o que validou o modelo (PONTIUS JR, 2008; PONTIUS JR, 2002; PONTIUS JR, 2000).

A segunda rodada ou processo de simulação do mapa futuro segue o fluxograma da figura 06. Os procedimentos do *Change Analysis*, *Transition Model* e *Change Prediction* com os novos mapas de uso do solo (2011 e 2013) foram refeitos na segunda rodada, projetando então o mapa de potencial de mudança da cobertura do solo para o ano de 2020 sem a nova via (Fig. 07) e com a nova via (Fig. 08). A taxa de acerto dos mapas projetados refere-se à taxa de validação do modelo.

Land Cover Prediction

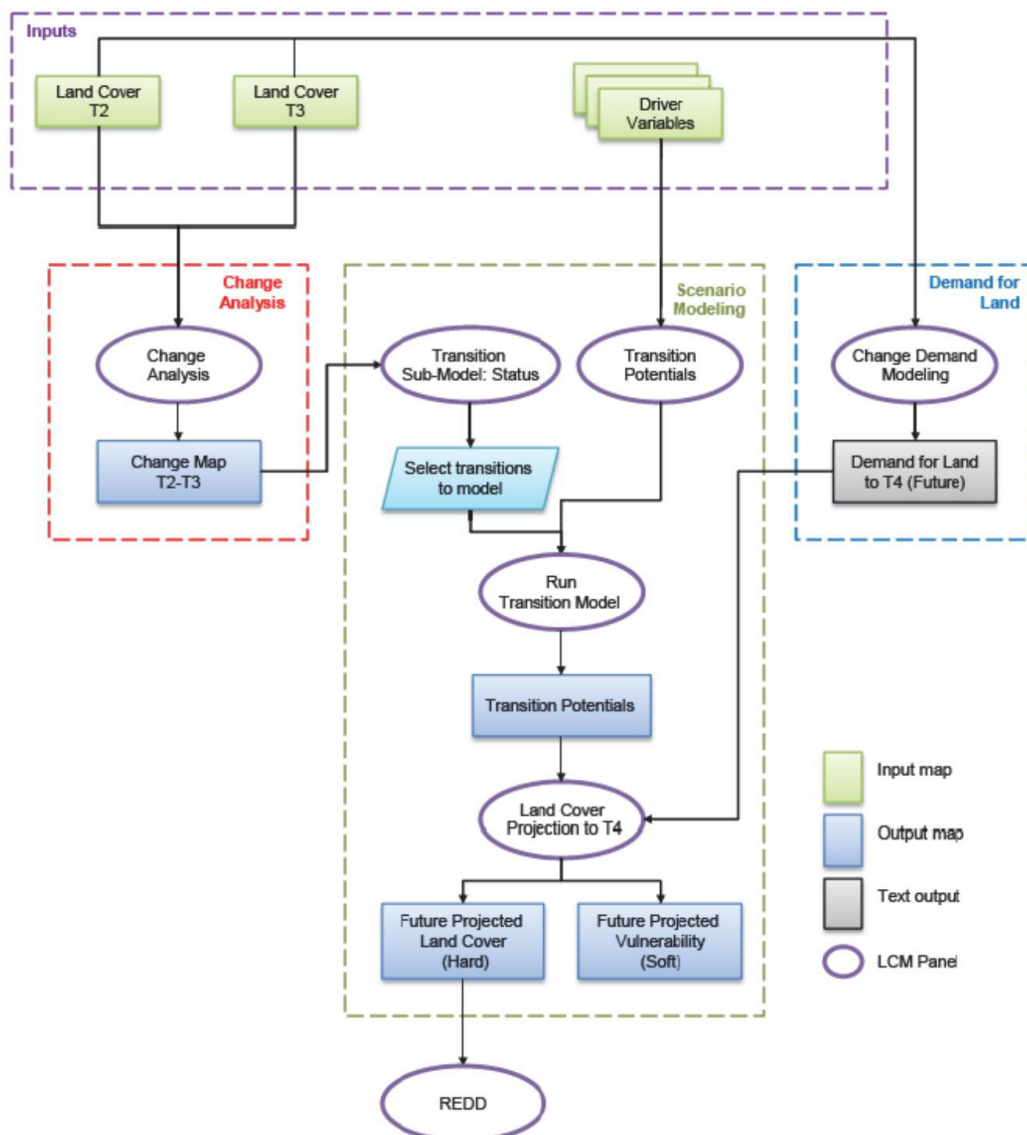


Figura 6: Fluxograma do processo de modelagem futura do uso do solo no LCM. Adaptado de (Eastman, J. R. 2012b).

3 - RESULTADOS E DISCUSSÃO

O cenário elaborado considerando os métodos de Cadeia de Markov e Automata Celular mostrou que há uma tendência ao aumento da mancha urbana através da perda de vegetação rasteira, predominantemente na porção noroeste do mapa. A maior concentração das mudanças apresenta um *hot spot* nas proximidades dos bairros Xangrilá, Trevo, Nova Pampulha, Garças e Braúnas. Esta área é classificada pelo zoneamento como Zona de Proteção 1 e 2 (ZP-1 e ZP-2) e se destina à proteção ambiental e preservação do patrimônio histórico, cultural, arqueológico ou paisagístico.

Como o método de Automato Celular considera que as mudanças ocorrerão junto aos

vizinhos mais próximos (filtro de 5x5), o método concentrou tais possíveis mudanças nas áreas mais próximas de onde ocorrerão as intervenções das obras. Soma-se a isto o fato de se ter uma maior concentração da tipologia de vegetação rasteira também nesta área, a qual apresenta maior probabilidade de se tornar urbano (classe 2) segundo a matriz markoviana de probabilidade condicional, quando comparado às outras tipologias. A tipologia água apresenta probabilidade zero de se tornar urbano, representado no mapa pela cor preto. E o que já é urbano é representado no mapa através da cor rosa.

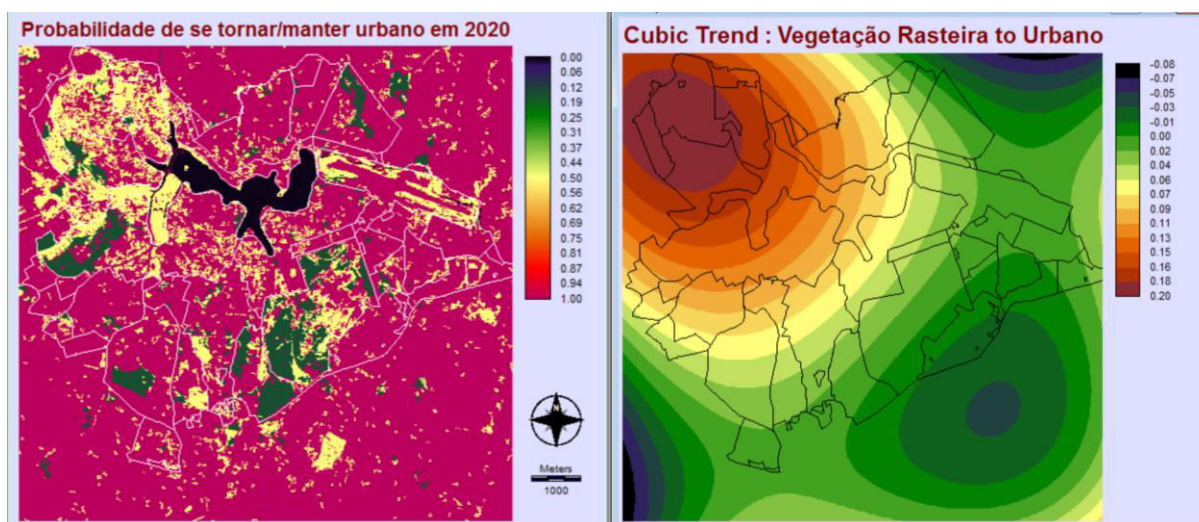


Figura 7: Probabilidade de se tornar urbano - Cenário CA-Markov

Os cenários elaborados pelo LCM, considerando as técnicas de Redes Neurais e Cadeia de Markov, são apresentados na Figura 7, com destaque para as áreas com maior probabilidade de mudanças, sem considerar a implantação da nova via, a borda noroeste da Lagoa da Pampulha. A Figura 08 mostra que, com a implantação da via, as transformações irão extrapolar a borda noroeste da Lagoa, e atingirão todo o entorno da lagoa. A diferença se dá pelo emprego da metodologia de redes neurais que, ao contrário dos automatas celulares que consideram o vizinho mais próximo, as as redes neurais consideram as conexões e interações entre as variáveis *drivers* e, portanto, extrapola o filtro de vizinhança.

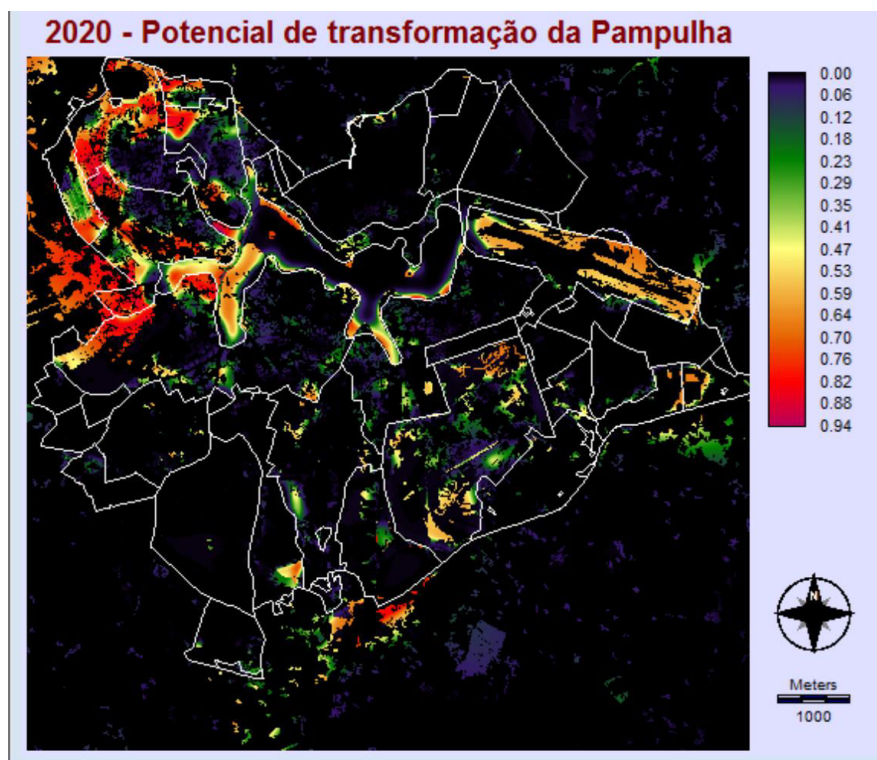


Figura 8: Potencial de transformação das tipologias de cobertura do solo para urbano no ano 2020

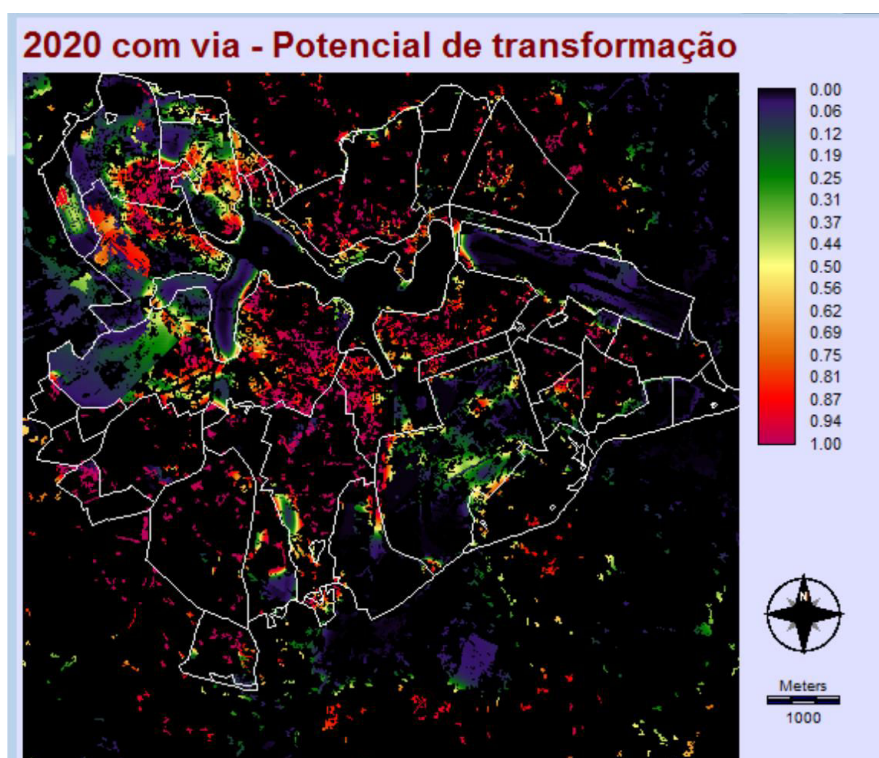


Figura 9: Potencial de transformação das tipologias de cobertura do solo para urbano no ano 2020 considerando a implantação de uma via de fluxo rápido na Regional Pampulha

CONSIDERAÇÕES FINAIS

A escolha do método na elaboração de rotinas de planejamento estratégico para ambientes urbanos deve considerar a aplicação de modelos espacialmente explícitos, ou seja, que o fator localização das mudanças seja algo relevante no desenvolvimento do modelo. Neste artigo foram comparados dois modelos espacialmente explícitos: Redes Neurais e Autômatos Celulares.

Como a lógica empregada na localização das mudanças em Autômatos Celulares (vizinho mais próximo) é diferente da lógica empregada por Redes Neurais (redes), o resultado do cenário simulado para a Regional Pampulha considerando a implantação de uma via de fluxo rápido é diferente.

Ambos os cenários identificam possíveis alterações na cobertura do solo na borda noroeste da Lagoa da Pampulha. Entretanto, o método baseado em Redes Neurais, propõe que a implantação da nova via na regional não ficará restrita a esta área, pelo contrário, abarcará toda o entorno da lagoa, preservando entretanto os fragmentos de vegetação densa que há na regional (parques). Desta forma, a escolha do método empregado pode influenciar o processo de tomada de decisão. Cabe então conhecer plenamente o objeto de estudo e seu território, de modo a ter condições de verificar como este se comporta, para que o método mais adequado seja escolhido.

REFERÊNCIAS:

- ATKINSON, Peter M.; TATNALL, A. R. L. **Introduction neural networks in remote sensing**. International Journal of remote sensing, v. 18, n. 4, p. 699-709, 1997.
- BRAIL, Richard K.; KLOSTERMAN, Richard E. **Planning Support Systems: Integrating Geographic Information Systems, Models, and Visualization Tools**. Redlands: ESRI, 2001.
- EASTMAN, J. R. **IDRISI Selva Manual**. Clark University. Sitio web: www.clarklabs.org, 2012.
- CHAN, Jonathan Cheung-Wai; CHAN, Kwok-Ping; YEH, Anthony Gar-On. **Detecting the nature of change in an urban environment: A comparison of machine learning algorithms**. Photogrammetric Engineering and Remote Sensing, v. 67, n. 2, p. 213-225, 2001.
- CIVCO, Daniel L. **Artificial neural networks for land-cover classification and mapping**. International Journal of Geographical Information Science, v. 7, n. 2, p. 173-186, 1993.
- GENARO, N. et al. **A neural network based model for urban noise prediction**. The Journal of the Acoustical Society of America, v. 128, n. 4, p. 1738-1746, 2010.
- GEOGRAPHICAL SCIENCES COMMITTEE et al. **Advancing Land Change Modeling: Opportunities and Research Requirements**. National Academies Press, 2014.

HARRIS, Britton. **Beyond geographic information systems**. Journal of the American Planning Association, v. 55, n. 1, p. 85-90, 1989.

HSIEH, William W. **Machine learning methods in the environmental sciences: neural networks and kernels**. Cambridge university press, 2009.

HOPKINS, Lewis D. **Structure of a planning support system for urban development**. Environment and Planning B, v. 26, p. 333-344, 1999.

KARUL, C.; SOYUPAK, S. **A comparison between neural network based and multiple regression models for chlorophyll-a estimation**. In: Ecological Informatics. Springer Berlin Heidelberg, 2003. p. 249-263.

PONTIUS, R.G.AND M. MILLONES. **Death to Kappa: birth of quantity disagreement and allocation disagreement for accuracy assessment**. International Journal of Remote Sensing; 2011.

PONTIUS JR, Robert Gilmore et al. **Comparing the input, output, and validation maps for several models of land change**. The Annals of Regional Science, v. 42, n. 1, p. 11-37, 2008.

PONTIUS, R.G. **Statistical methods to partition effects of quantity and location during comparison of categorical maps at multiple resolutions**. Photogrammetric Engineering & Remote Sensing, 68(10): 1041-1049; 2002.

PONTIUS, R.G. **Quantification error versus location error in comparison of categorical maps**. Photogrammetric Engineering & Remote Sensing, 66(8): 1011-1016; 2000.

ZYNGIER, Camila Marques et al. **Comunicação de paisagens possíveis: a experiência de montagem de um Planning Support System para Belo Horizonte**. 2014. Disponível em: http://www.cartografia.org.br/cbc/trabalhos/10/683/CT10-16_1404430423.pdf

CONSIDERAÇÕES FINAIS

O processo de simulação e projeção de cenários futuros para uso/cobertura do solo urbano é um processo complexo e exige um conhecimento aprofundado das relações que levam às mudanças, assim como de um banco de dados com informações que atendam os critérios técnicos (sistema de projeção, escala, metadados, qualidade dos dados) assim como critérios da pesquisa (acesso às informações necessárias para compor o Modelo de Simulação sobre o objeto de estudo).

Em geral, o Modelo de Simulação usa de técnicas estatísticas para calcular a probabilidade das mudanças e de métodos espacialmente explícitos para alocar no espaço geográfico as mudanças verificadas. Para calcular as probabilidades de transição, apresentamos neste trabalho alguns dos métodos mais usuais, tais como a Regressão e a Cadeia de Markov. Para a locação das mudanças no espaço geográfico, apresentamos os métodos de Autômatos Celular, Redes Neurais e citamos a Modelagem baseada em Agentes. O modelo baseado em *Exogenous Quantity* não considera o fator espacial na locação das mudanças, apenas a probabilidade estatística da mudança. Desta forma, aconselhamos o uso deste último modelo apenas para estudos cuja localidade das mudanças não seja um fator determinante.

Uma das características principais do Modelo de Simulação espacialmente explícitos é que este pode ou não apresentar variáveis *drivers* ou explicativas do processo dependendo do método escolhido. Ao incorporar as variáveis *drivers*, deve-se ater para o fato destas serem variáveis contínuas ou índices numéricos, com escala normalizada para facilitar a interpretação e comparação entre variáveis. O processo de seleção das variáveis para compor o Modelo de Simulação é outro ponto determinante na metodologia. Para auxiliar na seleção das variáveis, comparamos quatro métodos estatísticos de análise multivariada: Análise Fatorial, Monte Carlo, Crémer-Von-Mises e Regressão Logística. Dentre os métodos analisados, o que indicou as variáveis para compor o modelo com maior índice de validação foi a Análise Fatorial, seguida pelo método de Monte Carlo. O Método de Regressão Logística foi calculado considerando a variável dependente de cobertura do solo (variável categórica binária) e apresentou índices mais modestos quando comparados com as demais que foram usadas para validar um modelo cujo mapa de cobertura do solo apresentava quatro tipologias e não duas.

Observamos que o modelo que desconsiderou a presença das variáveis drives (CA-Markov) obteve validação de 95,02% e o que apresentou as variáveis drivers (LCM) obteve validação de 95,46%, o que nos mostra que ambos são aplicáveis nos estudos urbanos.

A diferença maior entre o modelo baseado em Cadeia de Markov e Autômatos Celulares (CA-Markov) e o modelo baseado em Cadeia de Markov e Redes Neurais (LCM) é que as mudanças no primeiro modelo são feitas considerando as imagens de probabilidade de mudança do módulo Markov e nestas imagens a probabilidade de mudança é a mesma para todos os pixels que compõem o mesmo estrato de tipologia de cobertura. A variação da mudança se dará com a aplicação do filtro de vizinhança do Autômato Celular, o qual adicionará no modelo um efeito de borda nos fragmentos. No modelo de Redes Neurais, do método de Cadeia de Markov é aproveitado apenas a matriz de transição de área, que informa quantos pixels sofrerão mudanças na tipologia. Com a informação do número de pixels, aplica-se o método de redes neurais para identificar quais pixels mudarão baseado no comportamento das variáveis drivers. Tal processo mostra-se, na Pampulha, ligeiramente mais eficiente. Entretanto, aplicado a áreas maiores é possível que esta diferença seja escalonada.

No Planejamento urbano, os Modelos de Simulação apresentam-se como ferramentas de apoio ao processo de decisão já que estes podem auxiliar na compreensão das dinâmicas que envolvem determinado território, assim como a simulação de cenários de acordo com os interesses dos grupos que detém o poder da decisão no setor de planejamento estratégico. Tais modelos permitem simular e verificar com antecedência a vida útil de determinadas políticas públicas e projetos assim como embasar tecnicamente tais decisões.

No que se refere aos mapas projetados para 2020, considerando que o padrão das transformações na paisagem se manterá o mesmo observado de 2009 a 2013, observamos que o método LCM (baseado em Redes Neurais, Cadeia de Markov e variáveis explicativas) projetou mudanças mais intensas do que o modelo CA-Markov (baseado em Cadeia de Markov, Autômato Celular e sem as variáveis explicativas) e o Modelo GEOMOD (baseado em Exogenous Quantity e variáveis explicativas), sendo este último o que projetou menos mudanças para a Pampulha até o ano de 2020, como pode ser visualizado nas figuras abaixo.

Observa-se ainda que os métodos LCM e CA-Markov identificam um vetor de mudanças que direciona-se da porção noroeste á sudeste, passando pela porção sul da Lagoa da Pampulha, enquanto que o GEOMOD identificou algumas áreas desconectas que sofrerão mudanças.

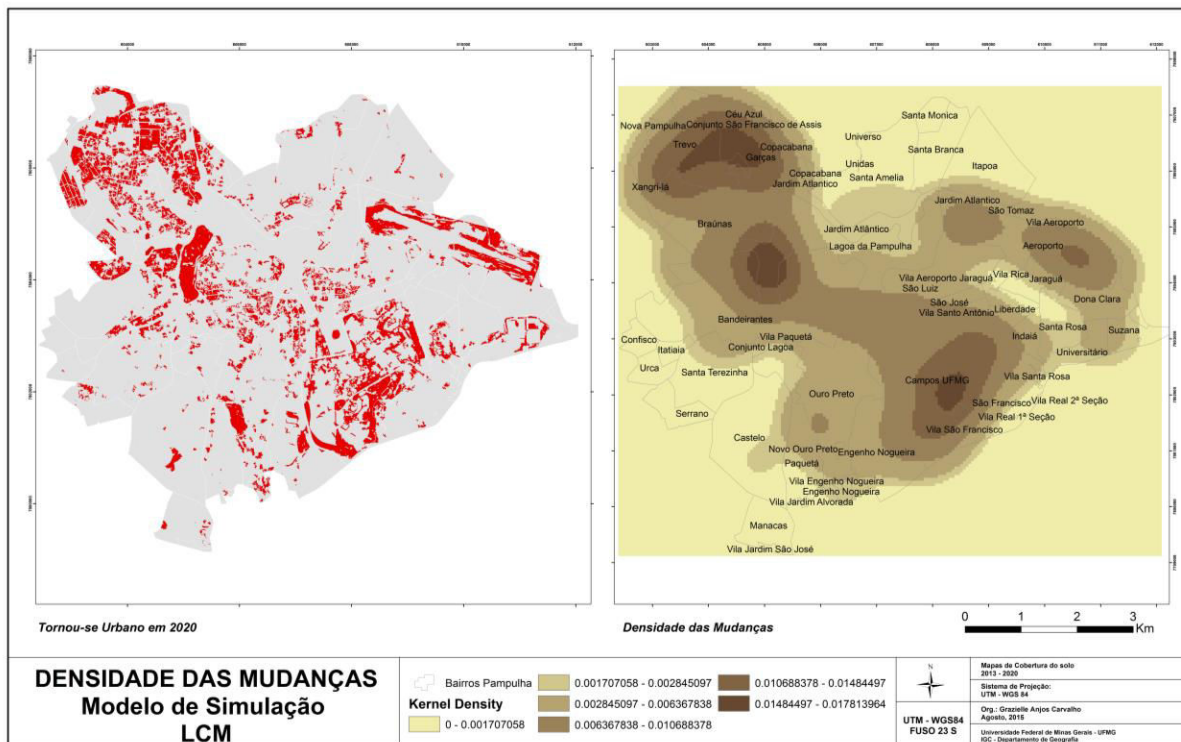


Figura 1:Densidade das mudanças projetadas na Regional Pampulha – Modelo de Simulação LCM

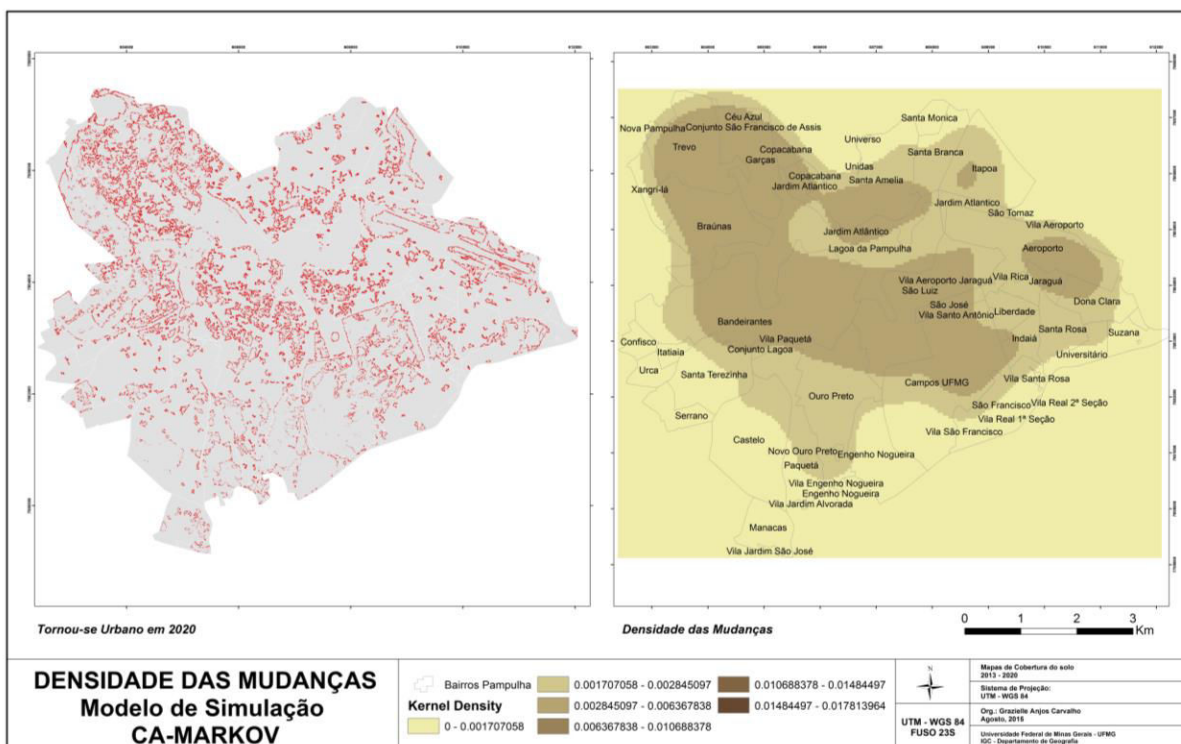


Figura 2:Densidade das mudanças projetadas na Regional Pampulha – Modelo de Simulação CA-MARKOV

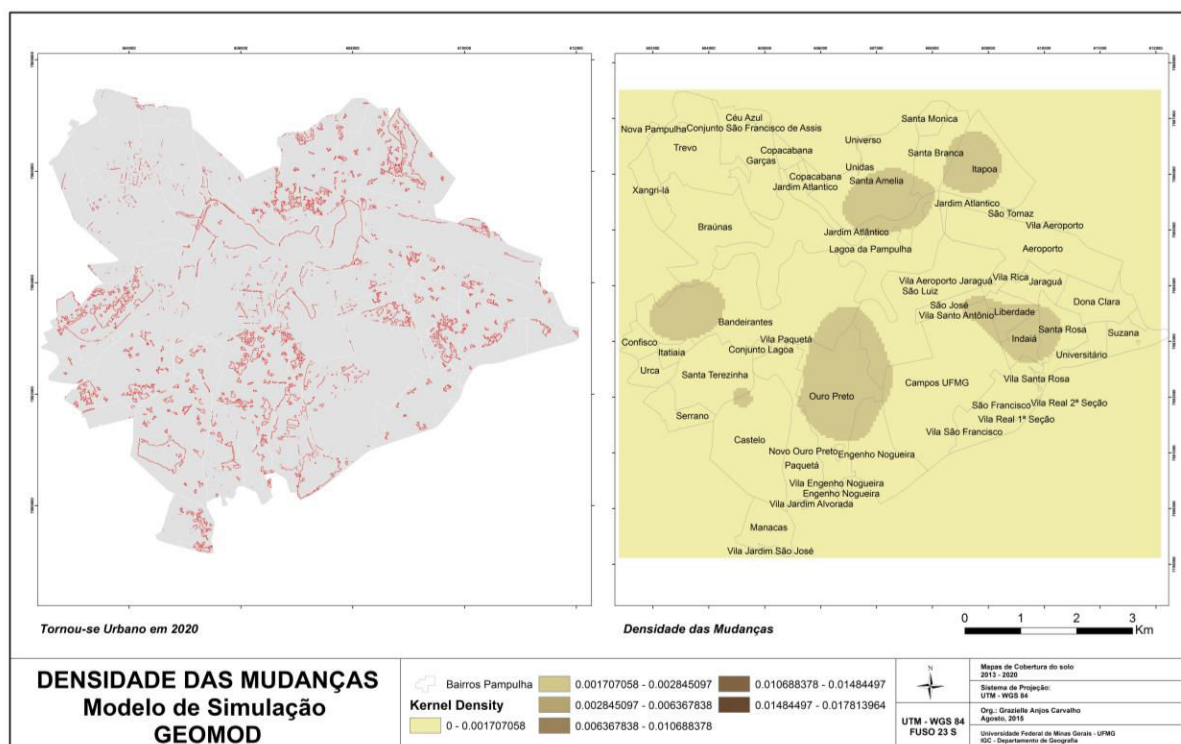


Figura 3: Densidade das mudanças projetadas na Regional Pampulha – Modelo de Simulação GEOMOD

As áreas de muita vegetação rasteira (Bairros da porção sul da lagoa e noroeste da regional) que aparecem com alto índice de transformação pode parecer estranho hoje pois, nos casos de existência de um grande lote a e muita superfície livre não significa que construirão nestes espaços outras edificações. Contudo, considerando a vinda de outras gerações que serão espólio dos primeiros, há o risco de mudança de padrão de uso e conseqüentemente do zoneamento, permitindo assim as potenciais mudanças aqui simuladas.

O maior desafio para que os Modelos de Simulação se tornem uma ferramenta acessível aos gestores é o banco de dados: Imagens de satélites em resolução espacial (de detalhe) e temporal para compor o modelo.

Os modelos que apresentaram melhores índices de validação necessitam de no mínimo 3 mapas de uso/cobertura do solo de tempos distintos, em escala compatível com a dinâmica urbana (muito detalhe), entretanto ainda não existe investimentos na organização e coletas destas informações na grande maioria das prefeituras brasileiras.

É preciso também a presença de um profissional que seja capaz de entender as dinâmicas espaciais no território estudado para que este estructure e identifique com maior agilidade as regras de transição que compõem o modelo de mudança.

REFERÊNCIAS

- ALMEIDA, C. M. **Modelagem da dinâmica espacial como uma ferramenta auxiliar ao planejamento: simulação de mudanças de uso da terra em áreas urbanas para as cidades de Bauru e Piracicaba (SP)** / C. M. Almeida. – São José dos Campos: INPE, 2003. 351p. – (INPE-10567-TDI/942/A). Acessado em 04/03/2013. Disponível em: http://www.dsr.inpe.br/geu/Teses%20de%20Doutorado/Tese_Claudia_Almeida.pdf
- ALMEIDA, C.M., CÂMARA, G. MONTEIRO, A.M.V. **Perspectiva histórica de modelos de dinâmicas urbanas e regionais**. In: ALMEIDA, C.M., CÂMARA, G. MONTEIRO, A.M.V.. (organizadores); apresentação de Michael Batty. *Geoinformação em urbanismo: cidade real X cidade virtual*. – São Paulo, Oficina de Textos, 2007.
- ANDERSSON, Claes; RASMUSSEN, Steen; WHITE, Roger. **Urban settlement transitions**. *Environment and Planning B*, v. 29, n. 6, p. 841-866, 2002.
- ANSELIN, Luc. **Exploring spatial data with GeoDaTM: a workbook**. *Urbana*, v. 51, p. 61801, 2004.
- ATKINSON, Peter M.; TATNALL, A. R. L. **Introduction neural networks in remote sensing**. *International Journal of remote sensing*, v. 18, n. 4, p. 699-709, 1997.
- AXELROD, R. **The Complexity of Cooperation: Agent-Based Models of Competition and Collaboration**, Princeton University Press, Princeton, NJ., 1997
- AXELROD, R. **Agent-based modelling as a bridge between disciplines**. In L. Tesfatsion & K. L. Judd (Eds.), *Handbook of computational economics: Agent-based computational economics (Vol. 2, pp. 1598–1583)*. Amsterdam: North-Holland, 2006.
- AXELROD, R. AND BENNETT, D. S. **A Landscape Theory of Aggregation**. *British Journal of Political Science*, 23, pp 211-233, 1993. doi:10.1017/S000712340000973X.
- AXTELL, R. **The emergence of firms in a population of agents: Local increasing returns, unstable nash equilibria, and power law size distributions**, Working paper no. 3. Washington DC: Center on Social and Economic Dynamics (The Brookings Institute), 1999.
- AXTELL, R., EPSTEIN, J.M., DEAN, J.S., GUMERMAN, G.J., SWEDLUND, A.C., HARBURGER, J., CHAKRAVARTY, S., HAMMOND, R., PARKER, J. AND PARKER, M., **Population Growth and Collapse in a Multiagent Model of the Kayenta Anasazi in Long House Valley**, *Proceedings of the National Academy of Sciences of the United States of America (PNAS)*, 99(3): 7275-7279, 2002.
- BAK, P., PACZUSKI, M., & SHUBIK, M. **Price variations in a stock market with many agents**, Discussion paper 1132 . New Haven: Cowles Foundation, (Yale University), 1999. Disponível em: <http://cowles.econ.yale.edu/P/cd/d11a/d1132.pdf>
- BATTY, Michael. **Building a science of cities** - *Cities*, Volume 29, Supplement 1, Pages S9-S16; March 2012.
- BATTY, M., & LONGLEY, P. A. **Fractal cities: A geometry of form and function**. San Diego, CA: Academic Press. 1994. Disponível em: www.fractalcities.org
- BATTY, Michael. **Cities and complexity: understanding cities with cellular automata, agent-based models, and fractals**. The MIT press, 2007a.

- BATTY, Michael. **Planning support systems: progress, predictions, and speculations on the shape of things to come.** 2007.
- BATTY, Michael & TORRENS, Paul M. **Modelling and prediction in a complex world.** *Futures*, v. 37, n. 7, p. 745-766, 2005.
- BATTY, Michael; XIE, Yichun; SUN, Zhanli. **Modeling urban dynamics through GIS-based cellular automata.** *Computers, environment and urban systems*, v. 23, n. 3, p. 205-233, 1999.
- BONABEAU, Eric. **Agent-based modeling: Methods and techniques for simulating human systems.** *Proceedings of the National Academy of Sciences of the United States of America*, v. 99, n. Suppl 3, p. 7280-7287, 2002.
- BRAGA, A. de P.; CARVALHO, ACPLF; LUDERMIR, Teresa Bernarda. **Redes neurais artificiais: teoria e aplicações.** *Livros Técnicos e Científicos*, 2000.
- BRAIL, Richard K.; KLOSTERMAN, Richard E. **Planning Support Systems: Integrating Geographic Information Systems, Models, and Visualization Tools.** Redlands: ESRI, 2001.
- BREDEWEG, Bert; SALLES, Paulo; NUTTLE, Tim. **Using exogenous quantities in qualitative models about environmental sustainability.** *AI Communications*, v. 20, n. 1, p. 49-58, 2007.
- BROWN, Warick M. et al. **Artificial neural networks: a new method for mineral prospectivity mapping.** *Australian Journal of Earth Sciences*, v. 47, n. 4, p. 757-770, 2000.
- BURROUGH, P. **Dynamic Modelling And Geocomputation.** In: P. Longley, M. Batty and R. McDonnel. *Geocomputation: A Primer.* London, John Wiley & Sons. 1998.
- CÂMARA, A. S. **Spatial Simulation Modelling.** In: M. Fisher. *Spatial Analytical Perspectives on GIS.* London, Taylor & Francis. 1996, pg. 213-218.
- CAPRA, Fritjof, **The Turning Point,** Simon & Schuster, Nova York, 1982. [O Ponto de Mutação, publicado pela Editora Cultrix, São Paulo, 1980]
- CAPRA, Fritjof. **A teia da vida: uma nova compreensão científica dos sistemas vivos.** Tradução: NEWTON ROBERVAL EICHEMBERG . Editora CULTRIX. São Paulo, 1996.
- CHAN, Jonathan Cheung-Wai; CHAN, Kwok-Ping; YEH, Anthony Gar-On. **Detecting the nature of change in an urban environment: A comparison of machine learning algorithms.** *Photogrammetric Engineering and Remote Sensing*, v. 67, n. 2, p. 213-225, 2001.
- CHANG, Chein-I. **Spectral information divergence for hyperspectral image analysis.** In: *Geoscience and Remote Sensing Symposium, 1999. IGARSS'99 Proceedings. IEEE 1999 International.* IEEE, 1999. p. 509-511.
- CHU, Hone-Jay; WU, Chen-Fa; LIN, Yu-Pin. **Incorporating spatial autocorrelation with neural networks in empirical land-use change models.** *Environment and Planning B: Planning and Design*, v. 40, n. 3, p. 384-404, 2013.
- CHRISTOFOLETTI, Antonio. **Modelagem de sistemas ambientais.** Edgard Blücher, 1999.
- CIVCO, Daniel L. **Artificial neural networks for land-cover classification and mapping.** *International Journal of Geographical Information Science*, v. 7, n. 2, p. 173-186, 1993.
- COSTA, F. H. S. e SOUZA FILHO, C. R. **Aplicação de redes neurais artificiais para reconhecimento de padrões em solos.** *Simpósio Brasileiro de Sensoriamento Remoto*, 14

(SBSR), p. 5177-5183, 2009.

COUCLELIS, H. **Cellular worlds: a framework for modelling micro-macro dynamics.** *Environment and Planning A*, 17, 585-596, 1985.

COUCLELIS, H. **From Cellular Automata to Urban Models: New Principles for Model Development and Implementation.** *Environment and Planning B: Planning and Design* 24: (1997). 165-174.

CRESPO, Ricardo; GRÊT-REGAMEY, Adrienne. **Local hedonic house-price modelling for urban planners: advantages of using local regression techniques.** *Environment and Planning B: Planning and Design*, v. 40, n. 4, p. 664-682, 2013.

CROOKS, Andrew T.; SEE, Linda M.; BATTY, Michael (Ed.). **Agent-based models of geographical systems.** Springer Netherlands, 2012.

CROOKS, A. T. **Using Geo-spatial Agent-Based Models for Studying Cities.** 2010. Acessado em Jan/2015. Disponível em: <http://www.css.gmu.edu/Andrew/pubs/paper160.pdf>

DE ANGELIS, D.L.; ROSE, K.A.; HUSTON, M.A. 1994. **Individual-oriented approaches to modeling ecological populations and communities.** Pages 390-410. In S. A. Levin editor. *Frontiers in Mathematical Biology.* Springer, Berlin.

DE BENITO, B. Pando; DE PEÑAS, J. Giles. **Greenhouses, land use change, and predictive models: MaxEnt and Geomod working together.** In: *Modelling Environmental Dynamics.* Springer Berlin Heidelberg, 2008. p. 297-317.

DE LIMA, Lucas Terres; DA CRUZ WEISS, Carlos Vinicius; DA SILVA, Marcelo Dutra. **Redes Neurais no estudo da paisagem: O estudo da paisagem do Parque Nacional da Lagoa do Peixe (Brasil) utilizando classificação de imagens de satélite por redes neurais.** *Revista de la Asociación Argentina de Ecología de Paisajes*, v. 4, n. 2, p. 219-225, 2013.

DE LIMA, Tiago França Melo et al. **Modelagem de sistemas baseada em agentes: Alguns conceitos e ferramentas.** *Anais XIV Simpósio Brasileiro de Sensoriamento Remoto*, Natal, Brasil, 25-30 abril 2009, INPE, p. 5279-5286.

DEANGELIS, Donald Lee et al. **Individual-based models and approaches in ecology: populations, communities and ecosystems.** Chapman & Hall, 1992.

DIAS T. L., CÂMARA, G., DAVIS JR. , C. A. **Modelos espaço-temporais.** In: *Bancos de dados geográficos.* INPE - São José dos Campos – 2005. Acessado em março de 2013. Disponível em: <http://mtc-m12.sid.inpe.br/col/sid.inpe.br/iris%401912/2005/07.01.19.53/doc/cap4.pdf>

DIMURO, Graçaliz P. et al. **Modelos de Markov e Aplicações.** VI Oficina de Inteligência Artificial, Pelotas: Educat, p. 37-59, 2002.

DOS REIS FREITAS, Leillimar; MARTINS FILHO, Sebastião; JÚNIOR, José Ivo Ribeiro. **Comparação das funções de ligação logit e probit em regressão binária considerando diferentes tamanhos amostrais.** *Enciclopédia Biosfera*, 2013.

DUSHKU, Aaron; BROWN, Sandra. **Spatial modeling of baselines for LULUCF carbon projects: the GEOMOD modeling approach.** In: *2003 International Conference on Topical Forests and Climate Change: "Carbon Sequestration and the Clean Development Mechanism.* 2003.

EASTMAN, J. R. **IDRISI Selva Tutorial.** Idrisi Production, Clark Labs-Clark University, v. 45, 2012a.

- EASTMAN, J. R. **IDRISI Selva Manual**. Clark University. Sitio web: www.clarklabs.org, 2012b.
- EL YACOUBI, Samira; CHOPARD, Bastien; BANDINI, Stefania (Ed.). **Cellular Automata: 7th International Conference on Cellular Automata for Research and Industry, ACRI 2006**, Perpignan, France, September 20-23, 2006, Proceedings. Springer, 2006.
- ENGELEN, Guy et al. **Using cellular automata for integrated modelling of socio-environmental systems**. Environmental monitoring and Assessment, v. 34, n. 2, p. 203-214, 1995.
- EPSTEIN, J. M. and AXTELL, R. **Growing artificial societies: social science from the bottom up**. Brookings Institution Press, 1996.
- FLAXMAN, Michael. **Fundamentals of Geodesign**. Proceedings Digital Landscape Architecture, Buhmann/Pietsch/Kretzel (Eds.): Peer Reviewed Proceedings Digital Landscape Architecture, Anhalt University of Applied Science, Germany, 2010.
- FERNANDES, Luiz Gustavo L.; PORTUGAL, Marcelo Savino; NAVAUX, Philippe OA. **Previsão de séries de tempo: redes neurais artificiais e modelos estruturais**. Pesquisa e Planejamento Econômico, v. 26, n. 2, p. 253-276, 1996.
- FIGUEIRA, Cleonis Viater. **Modelos de regressão logística**. Dissertação de Mestrado . Universidade Federal do Rio Grande do Sul, 2006.
- FUGLSANG, Morten; MÜNIER, Bernd; HANSEN, Henning Sten. **Modelling land-use effects of future urbanization using cellular automata: An Eastern Danish case**. Environmental Modelling & Software, v. 50, p. 1-11, 2013.
- FURTADO, Bernardo Alves; VAN DELDEN, Hedwig. **Modelagem urbana e regional com autômatos celulares e agentes: panorama teórico, aplicações e política pública**. 2011. Instituto de Pesquisas Econômica e aplicada - IPEA . Acessado em março de 2013. Disponível em: http://www.ipea.gov.br/sites/000/2/publicacoes/tds/td2_1576_Web.pdf
- GARBER, Daniel. Massachusetts. **Science and certainty in Descartes**. In Hooker, Michael (org.): Descartes, John Hopkins University Press, Baltimore, 1979.
- GENARO, N. et al. **A neural network based model for urban noise prediction**. The Journal of the Acoustical Society of America, v. 128, n. 4, p. 1738-1746, 2010.
- GEOGRAPHICAL SCIENCES COMMITTEE et al. **Advancing Land Change Modeling: Opportunities and Research Requirements**. National Academies Press, 2014.
- GIACOMINI, H. **Sete motivações teóricas para o uso da modelagem baseada no indivíduo em ecologia**. ACTA Amazônica . Acta Amaz. vol.37 no.3 Manaus, 2007. Disponível em: <http://www.scielo.br/pdf/aa/v37n3/v37n3a15.pdf>
- GILBERT, Nigel. **Agent-based models**. Sage, 2008.
- GHOSH, Ashish; DEHURI, Satchidananda. **Multi-objective evolutionary algorithms for knowledge discovery from databases**. Heidelberg: Springer, 2008.
- GOMES, Paula Madeira. **Modelagem da dinâmica do uso da terra e instrumentos de Política Ambiental: a expansão da cana-de-açúcar na Bacia Hidrográfica do Tiete/Jacaré (UGRHI 13)**. 2013. Tese de Doutorado. Universidade de São Paulo.
- GRIMM, Volker. **Ten years of individual-based modelling in ecology: what have we learned and what could we learn in the future?**. Ecological modelling, v. 115, n. 2, p. 129-148, 1999.

- GUILLAIN, Rachel; LE GALLO, Julie. **Agglomeration and dispersion of economic activities in and around Paris: an exploratory spatial data analysis.** Environment and planning. B, Planning & design, v. 37, n. 6, p. 961, 2010.
- HAGGETT, Peter; CHORLEY, Richard J. **Models, paradigms and the new geography.** Models in geography, v. 19, p. 41, 1967.
- HAGGETT, Peter; CHORLEY, Richard J. **Frontiers in geographical teaching.** Methuen, 1975.
- HARRIS, Britton. **Beyond geographic information systems.** Journal of the American Planning Association, v. 55, n. 1, p. 85-90, 1989.
- HATZICHRISTOS, Thomas. **Delineation of demographic regions with GIS and computational intelligence.** Environment and Planning B, v. 31, n. 1, p. 39-50, 2004.
- HERMANNNS, Holger. **Interactive Markov chains: and the quest for quantified quality.** Springer-Verlag, 2002.
- HOLZER, Werther. **Uma discussão fenomenológica sobre os conceitos de paisagem e lugar, território e meio ambiente.** Revista Território, v. 2, n. 3, p. 77-85, 1997.
- HOPKINS, Lewis D. **Structure of a planning support system for urban development.** Environment and Planning B, v. 26, p. 333-344, 1999.
- HSIEH, William W. **Machine learning methods in the environmental sciences: neural networks and kernels.** Cambridge university press, 2009.
- IBGE. **Censo Demográfico 2010. Características da população e dos domicílios: resultados do universo.** Rio de Janeiro: IBGE, 2011. Acompanha 1 CD-ROM. Acesso em: mar. 2013.
- ILACHINSKI, A. **Irreducible Semi-Autonomous Adaptive Combat (ISAAC): An artificial-life approach to land combat .** Alexandria: Center for Naval Analyses, 1997.
- ISLAM, Md Shahidul; AHMED, Raquib. **Land use change prediction in Dhaka city using GIS aided Markov chain modeling.** Journal of Life and Earth Science, v. 6, p. 81-89, 2011.
- JORGENSEN S.E. 1994. **Fundamentals of ecological modeling.**, 2^a ed. Elsevier Science B.V.
- KALIRAJ, S.; MALAR, V. K. **Geospatial analysis to assess the potential site for coal based Thermal Power station in Gujarat. India,** Advances in applied Science Research, p. 1554-1562, 2012.
- KAMUSOKO, Courage et al. **Rural sustainability under threat in Zimbabwe—simulation of future land use/cover changes in the Bindura district based on the Markov-cellular automata model.** Applied Geography, v. 29, n. 3, p. 435-447, 2009.
- KARUL, C.; SOYUPAK, S. **A comparison between neural network based and multiple regression models for chlorophyll-a estimation.** In: Ecological Informatics. Springer Berlin Heidelberg, 2003. p. 249-263.
- KAWATA, M. and TOQUENAGA, Y. **Artificial individuals and global patterns.** Trends in Ecology and Evolution 9:417-421, 1994
- KIM, Donghan; BATTY, Michael. **Calibrating Cellular Automata Models for Simulating Urban Growth: Comparative Analysis of SLEUTH and Metronamica.** Centre for Advanced Spatial Analysis, Paper, v. 176, 2011.

- KLOSTERMAN, R. E. **The what if? Collaborative planning support system.** *Environment and Planning B*, v. 26, p. 393-408, 1999.
- KOHLER, Timothy A.; GUMMERMAN, George J. **Dynamics of human and primate societies: agent-based modeling of social and spatial processes.** Oxford University Press, 2001.
- KOLLMAN, K., MILLER, J. H., & PAGE, S. E. **Adaptive parties in spatial elections.** *American Political Science Review*, 86 (4), 929–937, 1992.
- KUHN, C. **Uma análise sistêmica das transformações de uso do solo como suporte a decisão para o planejamento de Unidades de Conservação.** Estudo de caso: Parque Nacional do Superagui – PR. 2005. 163 f. Dissertação (Mestrado em Planejamento Urbano e Regional) - Universidade Federal do Rio Grande do Sul, Programa de Pós Graduação em Planejamento Urbano e Regional, Porto Alegre, 2005
- LI, Weidong; ZHANG, Chuanrong. **Linear interpolation and joint model fitting of experimental transiograms for Markov chain simulation of categorical spatial variables.** *International Journal of Geographical Information Science*, v. 24, n. 6, p. 821-839, 2010.
- LIESKE, Scott N.; HAMERLINCK, Jeffrey D. **Planning support systems applications in site planning.** *Urban Design and Planning: Proceedings of the ICE - Urban Design and Planning.* [s. L.], p. 34-42. 06 mar. 2012. Disponível em: <<http://www.icevirtuallibrary.com/content/article/10.1680/udap.11.00040>>. Acesso em: 21 jan. 2015.
- LEÃO, S. **Spatial-temporal model for demand and allocation of landfills in growing urban regions.** Department of Geomatics Engineering. 2002. Tese (Doutorado em Engenharia Geomática) - The University of Melbourne, Melbourne, Australia, 2002.
- LIMA, EDGAR BARBOSA. **Modelos microscópicos para simulação do tráfego baseados em autômatos celulares.** 2007. Tese de Doutorado. Master's thesis, Universidade Federal Fluminense.
- LIN, Yu-Pin et al. **Predictive ability of logistic regression, auto-logistic regression and neural network models in empirical land-use change modeling—a case study.** *International Journal of Geographical Information Science*, v. 25, n. 1, p. 65-87, 2011.
- LIU, Weiguo; SETO, Karen C. **Using the ART-MMAP neural network to model and predict urban growth: a spatiotemporal data mining approach.** *ENVIRONMENT AND PLANNING B PLANNING AND DESIGN*, v. 35, n. 2, p. 296, 2008.
- MACEDO, Rodrigo de Campos, et al. **Modelagem dinâmica espacial das alterações de cobertura e uso da terra relacionadas à expansão canavieira.** *Bol. Ciênc. Geod., sec. Artigos*, v. 19, n. 2, p. 313-337, 2013.
- MAES,P. (1995) **Modeling adaptive autonomous agents.** *Artificial life, An Overview.* C.G.Langton. Oxford, MIT Press: 135-162
- MANSON, S. M., AND T. EVANS. **Agent-based modeling of deforestation in southern Yucatán, Mexico, and reforestation in the Midwest United States.** *Proceedings of the National Academy of Sciences* , 2007.
- MARIA DE ALMEIDA, Cláudia et al. **Stochastic cellular automata modeling of urban land use dynamics: empirical development and estimation.** *Computers, Environment and Urban Systems*, v. 27, n. 5, p. 481-509, 2003.

- MEADOWS, Donella H. **Thinking in systems: A primer**. Chelsea Green Publishing, 2008.
- MEDEIROS, José Simeão de. **Bancos de dados geográficos e redes neurais artificiais: tecnologias de apoio à gestão do território**. 1999. Tese de Doutorado. Universidade de São Paulo.
- MELOTTI, Gledson. **Aplicação de Autômatos Celulares em Sistemas Complexos: Um Estudo de Caso em Espalhamento de Epidemias**. 2009. Tese de Doutorado. Universidade Federal de Minas Gerais.
- MEMARIAN, Hadi et al. **Validation of CA-Markov for simulation of land use and cover change in the Langat Basin, Malaysia**. Journal of Geographic Information System, v. 4, p. 542, 2012.
- MILLER, E. J. et al. **Microsimulating urban systems**. Computers, Environment and Urban Systems, v. 28, n. 1, p. 9-44, 2004.
- MISHRA, Varun Narayan; RAI, Praveen Kumar; MOHAN, Kshitij. **Prediction of land use changes based on land change modeler (LCM) using remote sensing: A case study of Muzaffarpur (Bihar), India**. Journal of the Geographical Institute Jovan Cvijic, SASA, v. 64, n. 1, p. 111-127, 2014.
- MITSOVA, Diana; SHUSTER, William; WANG, Xinhao. **A cellular automata model of land cover change to integrate urban growth with open space conservation**. Landscape and Urban Planning, v. 99, n. 2, p. 141-153, 2011.
- MULLIGAN, M.; WAINWRIGHT, J. **Modelling and model building**. In: MULLIGAN, M.; WAINWRIGHT, J. (Orgs.). Environmental modelling: finding simplicity in complexity, Chichester: John Wiley & Sons, 2004, p. 5-68.
- NAGABHATLA, Nidhi; FINLAYSON, C. Max; SELLAMUTTU, Sonali Seneratna. **Assessment and change analyses (1987-2002) for tropical wetland ecosystem using earth observation and socioeconomic data**. Eur. J. Rem. Sens, v. 45, p. 215-232, 2012.
- NAGEL, K. AND RASMUSSEN, S. **Traffic at the Edge of Chaos**. In Brooks, R. (ed.) Artificial Life IV, MIT Press, Cambridge, MA, pp. 222-236., 1994.
- NÓBREGA, R. P.; DE SOUZA FILHO, C. R. **Análise espacial guiada pelos dados (data-driven): o uso de redes neurais para avaliação do potencial poli-minerário na região centro-leste da Bahia**. Brazilian Journal of Geology, v. 33, n. 2, p. 111-120, 2003.
- NUSSENZVEIG, M. H. **Complexidade e Caos** / Organização de H. Moysés Nussenzveig. 3 ed. Rio de Janeiro: Editora UFRJ/Copea, 2008.
- OLIVEIRA, Paulo Murilo Castro de. **Autômatos Celulares**. In: NUSSENZVEIG, M. H. Complexidade e Caos / Organização de H. Moysés Nussenzveig. 3 ed. Rio de Janeiro: Editora UFRJ/Copea, 2008.
- O'SULLIVAN, David; TORRENS, Paul M. **Cellular models of urban systems**. In: Theory and Practical Issues on Cellular Automata. Springer London, 2001. p. 108-116.
- ONSTED, Jeffrey A.; CHOWDHURY, Rinku Roy. **Does zoning matter? A comparative analysis of landscape change in Redland, Florida using cellular automata**. Landscape and Urban Planning, v. 121, p. 1-18, 2014.
- OREKAN, Vincent O. A et al. **Implementation of the local land-use and land-cover change model CLUE-s for Central Benin by using socio-economic and remote sensing data**. Shaker Verlag, 2008.

NORTH, M. J., MACAL, C. M., & VOS, J. R. **Terrorist organization modelling**. North American Association for Computational Social and Organizational Science Conference 2004, Pittsburgh, 2004.

PAIVA, Wagner Peixoto de. **A teoria do caos e as organizações**. Caderno de Pesquisas em Administração, São Paulo, v. 08, nº 2, abril/junho 2001.

PALAZZO, Luiz Antônio Moro. **Complexidade, Caos e Auto-organização**. Universidade Católica de Pelotas, 2004. Acesso em 18 de Março de 2013. Disponível em: http://algol.dcc.ufla.br/~monserrat/isc/Complexidade_caos_autoorganizacao.html

PATUELLI, Roberto et al. **Neural networks and genetic algorithms as forecasting tools: a case study on German regions**. Environment and Planning B Planning and Design, V. 35, N. 4, P. 701, 2008.

PEDROSA, B. M. & CÂMARA, G.. **Modelagem Dinâmica e Geoprocessamento**. In: DRUCK, S.; CÂMARA G.; MONTEIRO, A. M.; CARVALHO, M. S. (ed). Análise Espacial de Dados Geográficos. Brasília, EMBRAPA, 2004.

PERES, O. M. & POLIDORI, M. C. **Modelos Urbanos baseados em Autômatos Celulares: integrando ambiente natural e o crescimento urbano**. 2009. Acessado em 04/03/2013, às 15:26 horas. Disponível em: <http://www.lbd.dcc.ufmg.br/colecoes/wcama/2009/010.pdf>

PÉREZ-VEGA, Azucena; MAS, Jean-François; LIGMANN-ZIELINSKA, Arika. **Comparing two approaches to land use/cover change modeling and their implications for the assessment of biodiversity loss in a deciduous tropical forest**. Environmental Modelling & Software, v. 29, n. 1, p. 11-23, 2012.

PETERNELLI, Luiz Alexandre. **Regressão Linear e Correlações** - Cap 09. 2007. Acessado em 31/12/2014. Disponível em: <http://www.dpi.ufv.br/~peterneli/inf162.www.16032004/materiais/CAPITULO9.pdf>

PREFEITURA DE BELO HORIZONTE. **Pampulha: modernização urbanística acelerada**. 200-. Acessado em Janeiro de 2015. Disponível em: <http://portalpbh.pbh.gov.br/pbh/>

POLIDORI, M. **Crescimento urbano e ambiente: um estudo exploratório sobre as transformações e o futuro da cidade**. 2004. 352 f. Tese (Doutorado em Ecologia) - Universidade Federal do Rio Grande do Sul, Programa de Pós Graduação em Ecologia, Porto Alegre, 2005.

PONTIUS JR, Robert Gilmore et al. **Comparing the input, output, and validation maps for several models of land change**. The Annals of Regional Science, v. 42, n. 1, p. 11-37, 2008.

PONTIUS, R.G. **Quantification error versus location error in comparison of categorical maps**. Photogrammetric Engineering & Remote Sensing, 66(8): 1011-1016, 2000

PONTIUS, R. G. J.; CHEN, H. **GEOMOD Modeling**. Land-use and cover change modeling. Note on GEOMOD modeling available within IDRISI Andes package. 2006.

PONTIUS JR, Robert Gilmore & MILLONES, Marco. **Death to Kappa: birth of quantity disagreement and allocation disagreement for accuracy assessment**, International Journal of Remote Sensing, 32:15, 4407-4429; 2011.

PONTIUS JR, R.G. **Quantification error versus location error in comparison of categorical maps**. Photogrammetric Engineering and Remote Sensing, 66, pp. 1011–1016; 2000.

- RALHA, Célia G. et al. **A multi-agent model system for land-use change simulation.** Environmental Modelling & Software, v. 42, p. 30-46, 2013.
- RASHMI, M. K.; LELE, N. **Spatial modeling and validation of forest cover change in Kanakapura region using GEOMOD.** Journal of the Indian Society of Remote Sensing, v. 38, n. 1, p. 45-54, 2010.
- ROY, Geoffrey G.; SNICKARS, Folke. **City life; a study of cellular automata in Urban Dynamics.** Spatial Analytical Perspectives and GIS, Taylor and Francis, London, p. 213-229, 1996.
- RUHOFF, Anderson Luis; CRUZ, Ibraim Fantin da; COLLISCHONN, Walter. **Modelos de simulação dinâmica do desmatamento na Amazônia.** 2010. Acessado em dezembro de 2014. Disponível em: <http://www.repositorio.furg.br:8080/handle/1/871>
- SANDERS, Lena et al. **SIMPOP: a multiagent system for the study of urbanism.** Environment and Planning B, v. 24, p. 287-306, 1997.
- SANTOS, Milton. **Pensando o espaço do homem.** 4. ed. São Paulo: Hucitec, 1997.
- SASSO, Juliana Bonás; CHIMARA, Henrique Dal Bo; MONTEIRO, Luiz Henrique Alves. **Epidemias e modelos epidemiológicos baseados em autômatos celulares: uma breve revisão.** Cad. de Pós-Graduação em Eng. Elétrica, v. 4, n. 1, p. 71-8, 2004.
- SCHELLING, T.C. **Dynamic Models of Segregation,** Journal of Mathematical Sociology, 1(1): 143-186., 1971.
- SERPA, Angelo. **Milton Santos e a paisagem: parâmetros para a construção de uma crítica da paisagem contemporânea.** Paisagem e Ambiente, n. 27, p. 131-138, 2010.
- SIMMONDS, David C. **The design of the DELTA land-use modelling package.** Environment and Planning B, v. 26, p. 665-684, 1999.
- SOARES FILHO, Britaldo Silveira. **Modelagem da dinâmica de paisagem de uma região de fronteira de colonização amazônica.** 1998. Tese de Doutorado. Universidade de São Paulo.
- SOARES-FILHO, Britaldo Silveira, et al. **Modelagem de dinâmica de paisagem: concepção e potencial de aplicação de modelos de simulação baseados em autômato celular.** Ferramentas para modelagem da distribuição de espécies em ambientes tropicais. Belém (disponível em www.csr.ufmg.br/dinamica), 2003.
- STACEY, R. D. **The chaos frontier: creative strategic control for business.** Oxford: Butterworth Heinmann, 1991.
- STEINITZ, C. **A Framework for Geodesign.** Esri Press, to be published in 2012.
- SUN, Jian et al. **CA-Based Urban Land Use Prediction Model: A Case Study on Orange County, Florida, US.** Journal of Transportation Systems Engineering and Information Technology, v. 12, n. 6, p. 85-92, 2012.
- TANG, Zhenghong. **Linking planning theories with factors influencing local environmental-plan quality.** 2008. Acessado em dezembro de 2014. Disponível em: http://digitalcommons.unl.edu/arch_crp_facultyschol/5/
- TESFATSION, L. and JUDD, K.L. **Handbook of Computational Economics: Agent-Based Computational Economics Volume 2,** North-Holland Publishing, Amsterdam, 2006.
- TRIOLA, Mario F. et al. **Introdução à estatística.** Rio de Janeiro: Ltc, 2005.

- TOBLER, W. **Cellular Geography**. In GALE, S. & OLSSSEN, G. (Eds.) *Philosophy in Geography*. Dordrecht, Reidel, 1979
- TOPA, G. **Social interactions, local spillovers and unemployment**. *The Review of Economic Studies*, 68 (2), 261–295. (2001).
- TORRENS, P.M. **How Land-Use-Transportation Models Work**, Centre for Advanced Spatial Analysis (University College London): Working Paper 20, London, 2000.
- UMBELINO, G. BARBIERI, A. **Uso de Autômatos Celulares em estudos de população, espaço e ambiente**. XVII Encontro Nacional de Estudos Populacionais – ABEP – Caxambu – 20 a 24 de Setembro de 2010. Acessado em 04/03/2013, às 15:45 horas. Disponível em: http://www.abep.nepo.unicamp.br/encontro2010/docs_pdf/eixo_2/abep2010_2432.pdf
- UMBELINO, G. J.M. **Simulações de distribuição espacial domiciliar e projeções demográficas intraurbanas com apoio de geotecnologias**. 2012. Tese de Doutorado - Universidade Federal de Minas Gerais, Programa de Pós Graduação em Demografia, Belo Horizonte, 2012.
- VALENCIA, David et al. **FPGA design and implementation of a fast pixel purity index algorithm for endmember extraction in hyperspectral imagery**. In: *Optics East 2005*. International Society for Optics and Photonics, 2005. p. 599508-599508-10.
- VELDKAMP, A.; FRESCO, L. O. **CLUE-CR: an integrated multi-scale model to simulate land use change scenarios in Costa Rica**. *Ecological modelling*, v. 91, n. 1, p. 231-248, 1996.
- VERBESSELT, Jan et al. **Detecting trend and seasonal changes in satellite image time series**. *Remote sensing of Environment*, v. 114, n. 1, p. 106-115, 2010.
- VERSTEGEN, Judith A. et al. **Identifying a land use change cellular automaton by Bayesian data assimilation**. *Environmental Modelling & Software*, v. 53, p. 121-136, 2014.
- WADDELL, P. **UrbanSim: Modeling urban development for land use, transportation, and environmental planning**. *Journal of the American Planning Association*, v. 68, n. 3, p. 297-314, 2002.
- WANG, Jida; MOUNTRAKIS, Giorgos. **Developing a multi-network urbanization model: A case study of urban growth in Denver, Colorado**. *International Journal of Geographical Information Science*, v. 25, n. 2, p. 229-253, 2011.
- WERNER, Francisco E. et al. **Spatially-explicit individual based modeling of marine populations: a review of the advances in the 1990s**. *Sarsia*, v. 86, n. 6, p. 411-421, 2001.
- WHITE R; ENGELEN G. **Cellular automata as the basis of integrated dynamic regional modeling**. *Environment and Planning B: Planning and Design*, 1997, 24(2): 235–246.
- XIMENES, A. de C. et al. **Modelagem Dinâmica do desmatamento na Amazônia**. *Boletim de Ciências Geodésicas*, v. 14, n. 3, p. 370-391, 2008.
- ZYNGIER, Camila Marques et al. **Comunicação de paisagens possíveis: a experiência de montagem de um Planning Support System para Belo Horizonte**. 2014. Disponível em: http://www.cartografia.org.br/cbc/trabalhos/10/683/CT10-16_1404430423.p