

**Universidade Federal de Minas Gerais**  
**Instituto de Geociências**  
**Programa de Pós-Graduação em Análise e Modelagem de Sistemas**  
**Ambientais**

**Rafaella Almeida Silvestrini**

**Modelo probabilístico de ignição e propagação de fogo**  
**em áreas de floresta na Amazônia Brasileira**

**Belo Horizonte**  
**2008**

Rafaella Almeida Silvestrini

**Modelo probabilístico de ignição e propagação de fogo  
em áreas de floresta na Amazônia Brasileira**

Dissertação apresentada ao Programa de Pós Graduação em Análise e Modelagem de Sistemas Ambientais da Universidade Federal de Minas Gerais como requisito parcial para obtenção do título de mestre em Análise e Modelagem de Sistemas Ambientais.

Orientador: Britaldo Silveira Soares Filho

Co-orientador: Renato Martins Assunção

Belo Horizonte  
Instituto de Geociências da UFMG  
2008



Universidade Federal de Minas Gerais  
Instituto de Geociências  
Mestrado em Análise e Modelagem de Sistemas Ambientais

Aprovada pela Banca Examinadora em cumprimento a requisito exigido para obtenção do Título de **Mestre em Análise e Modelagem de Sistemas Ambientais**.

Dr. Britaldo Silveira Soares Filho – IGC/UFMG

Orientador

Dr. Renato Martins Assunção – Departamento de Estatística/UFMG

Co-orientador

Dr. Sergio Donizete Faria – IGC/UFMG

Membro da banca, Convidado

Dr. Alberto Setzer – INPE

Membro da banca, Convidado

Belo Horizonte, 10 de dezembro de 2008

À minha família e a todos que  
lutam pela conservação da  
Amazônia.

## **AGRADECIMENTOS**

Ao Britaldo Soares-Filho, meu orientador, competente e dedicado, com quem pude contar todo o tempo. Agradeço pela confiança depositada em meu trabalho e pelas oportunidades acadêmicas.

Ao Renato Assunção não apenas pela co-orientação, mas também por todo apoio e aprendizado que, durante a graduação, despertaram meu interesse pelo uso da estatística voltada ao meio ambiente.

Aos colegas do CSR, cuja ajuda foi indispensável para o andamento deste estudo.

À Ane Alencar pelas discussões e pelo compartilhamento dos dados.

Aos professores e colegas da Pós-Graduação pela companhia nesta jornada.

À minha família pelo apoio e incentivo.

Agradeço ao IPAM – Instituto de Pesquisa Ambiental da Amazônia -, em especial a Elsa Mendoza, pela concessão da bolsa de mestrado.

## RESUMO

A modelagem de fogo tornou-se uma importante ferramenta na avaliação da resiliência de ambientes florestais em situações de intervenções humanas, bem como na interação entre desmatamento e clima, fatores que podem levar o ecossistema amazônico a um ciclo irreversível de destruição. O objetivo deste estudo é a criação de um modelo probabilístico capaz de simular tanto as fontes de ignição quanto a propagação do fogo na Amazônia Brasileira, através de dois componentes. O primeiro componente simula a ocorrência de focos de calor, representando as fontes de ignição ao longo das áreas de floresta da Amazônia, baseado na integração de dados climáticos e de uso da terra. Calibrou-se este modelo com focos de calor do satélite NOAA-12 noite ocorridos em 2003 e a validação realizou-se com dados de 2002, 2004 e 2005. Primeiramente, utilizou-se o método de pesos de evidência para estimar a probabilidade de focos de calor baseada em uma série de variáveis espaciais – como proximidade a estradas, cidades, áreas desflorestadas e uso da terra. Este mapa foi combinado a um mapa de risco climático, derivado da aplicação de uma regressão logística a dados mensais de VPD (déficit de pressão de vapor), resultando, finalmente, no mapa de risco de focos de calor. Considerando este mapa de risco, o modelo simula estocasticamente a quantidade e a localização dos focos de calor mensalmente, utilizando coeficientes de ajuste para as estações secas e chuvosas dos hemisférios sul e norte e duas distribuições de probabilidade, a distribuição Beta(0,985;0,1) e a Weibull(13;0,6). Em relação à propagação, o objeto de estudo é um tipo de fogo bastante usual nas florestas da Amazônia, o fogo de sub-bosque, o qual os satélites de monitoramento não conseguem captar facilmente. A componente do espalhamento emprega a metodologia de autômato celular para simular a propagação do fogo como função da distância das fontes de ignição - obtidas pelo primeiro componente do modelo - declividade, hidrografia, condições climáticas e direção do vento no interior da floresta. Nesta fase, utilizaram-se cicatrizes de fogo obtidas através de imagens LandSat na região do Xingu em 2005. Ambas as etapas da modelagem apresentaram ajustes satisfatórios em termos de distribuição espacial e temporal.

## SUMÁRIO

<b>CONSIDERAÇÕES INICIAIS</b> .....	1
<b>ARTIGO: Simulating forest fire risk and occurrence in the Brazilian Amazon</b> .....	5
Abstract .....	6
1. Introduction .....	7
2. Model development.....	10
2.1. Anthropogenic risk of fire .....	10
2.2. Climatic risk of fire .....	12
2.3. Integrating anthropogenic and climatic risks .....	14
2.4. Hot pixel simulation .....	14
2.5. Model validation .....	16
3. Results .....	18
4. Discussion .....	25
5. Conclusion.....	27
6. Acknowledgments.....	27
References .....	28
<b>ARTIGO: Modelo probabilístico de propagação de fogo: aplicação para a região do Xingu</b> .....	35
Abstract .....	36
1. Introdução.....	37
2. Materiais e métodos .....	39
2.1. Probabilidade referente à distância custo .....	40
2.2. Probabilidade relacionada ao clima no interior da floresta .....	41
2.3. Simulação do mecanismo de propagação do fogo .....	42
3. Resultados e discussão .....	43
4. Conclusões .....	46
Agradecimentos.....	46
Referências bibliográficas .....	47
<b>CONSIDERAÇÕES FINAIS</b> .....	50

## CONSIDERAÇÕES INICIAIS

O fogo é considerado um dos principais eventos que vem alterando a dinâmica da floresta Amazônica. No período El-Niño de 1997-98 a área queimada - 40.000 Km<sup>2</sup> (Nepstad et al., 1999a) - correspondeu a duas vezes a área média desmatada anualmente entre 1988 e 2005 - aproximadamente 18.500 Km<sup>2</sup> (INPE, 2008). Além de trazer danos ao ambiente natural, por modificarem o solo, a vegetação e a biodiversidade, os incêndios florestais afetam a saúde humana ao alterar a composição e os processos de purificação da atmosfera, aumentando o tempo de residência das partículas de fumaça no ar e diminuindo a quantidade de chuvas. Durante a grande seca que atingiu o oeste da Amazônia em 2005, causada provavelmente pelo aquecimento do Atlântico Norte Tropical (Marengo et al., 2008), apenas no estado do Acre mais de 400.000 pessoas foram prejudicadas pela fumaça decorrente dos 300.000 ha de floresta atingidos pelo fogo neste estado (Brown et al., 2006). Futuramente, a expectativa de crescimento em severidade e frequência dos eventos climáticos extremos associados ao aquecimento global (Cox et al., 2004), aliado à crescente expansão das fronteiras agrícolas, poderá fazer com que os danos causados pelo fogo sejam ainda maiores.

Na Amazônia o fogo se concentra ao longo das porções leste e sul, na região denominada arco do desmatamento, devido à localização de secas sazonais severas e atividades que potencializam o risco de fogo – como exploração madeireira, desmatamento e áreas de agricultura e pecuária – nesta região (Ray et al., 2005). Considerando a expansão das atividades previamente mencionadas, estima-se que 55% da floresta tropical da Amazônica – que contém o maior sistema fluvial do planeta e é essencial para resfriar a temperatura mundial (Nepstad, 2007) – pode ser destruída ou seriamente danificada por volta de 2030 (Soares-Filho et al., 2006). A inclusão do empobrecimento da floresta causado pelo fogo aumentaria ainda mais esta estimativa, contudo ela não foi realizada devido à inexistência de modelos que simulem a ignição, espalhamento e extinção de um incêndio.

Frente às perspectivas acima e considerando todos os efeitos negativos no meio ambiente, o estudo e desenvolvimento de modelos de fogo para a Amazônia tornam-se importantes para quantificar a degradação da floresta no futuro e servir como ferramenta auxiliar na tomada de decisão em relação às políticas a serem implementadas na região.

Os diversos índices de fogo utilizados mundialmente baseiam-se em princípios da física ou abordagem estatística e foram desenvolvidos por órgãos do governo ou pesquisadores independentes. Exemplos de índices bastante desenvolvidos no exterior incluem o índice elaborado pelo Serviço Florestal do Canadá, denominado CFFDRS -



Canadian Forest Fire Danger Rating System - (Canadian Forest Service, 2007) e o elaborado pelo Serviço Florestal dos Estados Unidos, chamado NFDRS - National Fire Danger Rating System - (NWCG, 2002). Ambos consistem em múltiplos componentes – dentre eles ignição, comportamento do fogo e modelos de combustíveis – e vários parâmetros, que devem ser combinados de maneira a adaptar às diferentes características do clima e vegetação nos dois países. No Brasil, o primeiro índice de perigo de fogo refere-se ao Índice de Monte Alegre – IMA - desenvolvido para o estado do Paraná por Soares (1972, 1998), que considera a umidade relativa do ar e número de dias sem chuva para predizer o risco de ignição. Recentemente, foi incorporada a este índice a velocidade do vento, permitindo que ele reflita também o potencial de propagação dos incêndios florestais (Nunes et al., 2005). A variedade de índices reflete a diversidade de paisagens e clima ao longo do planeta, de maneira que nenhum dos índices mencionados pode ser aplicado na Amazônia sem serem reparametrizados e testados.

Uma iniciativa brasileira que vem colaborando para o acompanhamento dos eventos de fogo na Amazônia foi a criação de um sistema de monitoramento no qual vários satélites captam a ocorrência de fogo na América do Sul através da seleção de pixels com temperatura elevada, denominados focos de calor, que são disponibilizados gratuitamente na internet (<http://www.cptec.inpe.br/queimadas>). Utilizando dados deste sistema, foram desenvolvidos alguns modelos de risco de fogo que podem ser aplicados na região Amazônica. Sismanoglu e Setzer (2005) utilizam dados climáticos e de vegetação, obtidos através de sensoriamento remoto, para calcular o risco de fogo diário em resolução de 25 km em todo o território brasileiro. Cardoso et al. (2003) estima o número de focos de calor em uma célula de 2,5° x 2,5 ° para o período de seca na Amazônia, junho a outubro, baseado em informações de condições climáticas, cobertura florestal e estradas. Por fim, o modelo RisQue (Nepstad et al., 2004) mensura o risco de ocorrência de fogo através da avaliação da quantidade de água disponível no solo em resolução de 8 km e espaço de tempo mensal. Apesar de constituir uma ferramenta bastante útil no monitoramento do fogo e na elaboração de modelos, a utilização dos focos de calor subestima a ocorrência de incêndios florestais uma vez que o fogo que corre abaixo do dossel, fogo de sub-bosque, dificilmente é captado como um foco (Nepstad et al., 1999) e sua identificação necessita de processamento digital de imagens.

Com a existência dos dados de focos de calor e o mapeamento de cicatrizes de incêndio de sub-bosque através de imagens Landsat, o presente estudo tem por objetivo desenvolver um modelo probabilístico para o cálculo de mapas mensais de probabilidade e de

simulação tanto para as fontes de ignição, representadas pelos focos de calor, quanto para a propagação do fogo, incluindo aqueles de sub-bosque.

Este trabalho é requisito parcial para a obtenção do título de Mestre em Análise e Modelagem de Sistemas Ambientais, do Instituto de Geociências da Universidade Federal de Minas Gerais. Optou-se pela dissertação em forma de dois artigos, conforme regulamento deste programa. O primeiro, submetido à revista *Global Change Biology* em fevereiro de 2009, trata da modelagem dos focos de calor em áreas de floresta da Amazônia Brasileira, enquanto o segundo, submetido ao XIV Simpósio Brasileiro de Sensoriamento Remoto, descreve a modelagem do espalhamento do fogo a partir de um foco de calor em áreas de floresta na região do Xingu, norte do Mato Grosso.

## Referências Bibliográficas

- Balch, J.K.; Nepstad, D.C.; Brando, P.M.; Curran, L.C.; Portela, O.; de Carvalho Jr, O.; e Lefebvre, P. Negative fire feedback in a transitional forest of Southeastern Amazonia. *Global Change Biology*, v. 14, p. 1-12, 2008.
- Brown, I.F.; Schroeder, W.; Setzer, A.; Maldonado, M.; Pantoja, N.; Duarte, A. and Marengo, J. Fires in rain forests of southwestern Amazonia: Multi-national satellite imagery for monitoring and for informing the public. *EOS Transactions*, v. 87, n. 26, p. 253-264, 2006.
- Canadian Forest Service, 2007. Canadian Forest Fire Danger Rating System (CFFDRS). Disponível em: <[http://cwffis.cfs.nrcan.gc.ca/en/background/bi\\_FDR\\_summary\\_e.php](http://cwffis.cfs.nrcan.gc.ca/en/background/bi_FDR_summary_e.php)>. Acesso em 04. nov. 2008.
- Cardoso, M.F.; Hurtt C.G.; Moore, B.; Nobre, C.A.; Prins, E.M. Projecting future fire activity in Amazonia. *Global Change Biology*, v. 9, p. 656 – 669, 2003.
- Cox, P.M.; Betts, R.A.; Collins, M.; Harris, P.P.; Huntingford, C.; Jones, C.D.; Amazonian forest dieback under climate-carbon cycle projections for the 21st century. *Theoretical and Applied Climatology*, v. 78, p. 137-156, 2004.
- INPE. Monitoramento da floresta amazônica brasileira por satélite Project PRODES. Disponível em: <<http://www.obt.inpe.br/prodes/index.html>> Acesso em 04. nov. 2008.
- Marengo, J.A.; Nobre, C.A.; Tomasella, J.; Oyama, M.D.; Oliveira, G.S.; Oliveira, R.; Camargo, H.; Alves, L.M.; Brown, I.F. The Drought of Amazonia in 2005. *Journal of Climate*, v. 21, n. 3, p. 495-516, 2008.
- Nepstad, D. The Amazon's Vicious Cycles. Drought and fire in the greenhouse. Ecological and climatic tipping points of the world's largest tropical rainforest and practical preventative measures. World Wildlife Fund. In:

United Nations Framework Convention on Climate Change (UNFCCC) Conference of the Parties (COP),  
Dezembro, 2007, Bali, Indonesia. Disponível em:

<[http://www.whrc.org/resources/published\\_literature/pdf/NepstadWWF.07.pdf](http://www.whrc.org/resources/published_literature/pdf/NepstadWWF.07.pdf)>. Acesso em 20 jun. 2008.

Nepstad, D.C.; Lefebvre, P.; Silva, U.L.; Tomasella, J.; Schlesinger, P.; Solórzano, L.; Moutinho, P.; Ray, D.; e  
Guerreira Benito, J. Amazon drought and its implications for Forest flammability and tree growth: a basin wide  
analysis. *Global Change Biology*, v. 10, p. 1–14, 2004.

Nepstad, D. C.; Moreira, A. G.; Alencar, A. Flames in the rain forest: Origins, impacts and alternatives to  
Amazonian Fire. Brasília: Editora Universidade de Brasília, 1999b, 140 p.

Nepstad DC, Veríssimo A, Alencar A et al. (1999a) Large-scale impoverishment of Amazonian forests by  
logging and fire. *Nature*, 398, 505-508.

Nunes, J. R. S. ; Soares, R. V. ; Batista, A C . FMA+ - Um novo índice de perigo de incêndios florestais para o  
estado do Paraná. In: Seminário de atualidades em proteção florestal, 2., 2005, Blumenau - SC. Anais ...

Blumenau: UFPR/FURB/FUPEF. 2005. v. 1. p. 1- 12. Disponível em

<<http://www.floresta.ufpr.br/firelab/artigos/artigo09.pdf>> Acesso em 04. Nov. 2008.

NWCG – National Wildfire Coordinating Group (2002). Gaining an Understanding of the National Fire Danger  
Rating System. Disponível em <<http://www.nwcg.gov/pms/pubs/MasterGaining.pdf>>. Acesso em 25. out.  
2007.

Ray, D.; Nepstad D. C.; Moutinho, P. Micrometeorological and Canopy Controls of fire susceptibility in an East-  
Central Amazon Landscape. *Ecological Applications*, v. 15, n. 5, p. 1664-1678, 2005.

Sismanoglu R.A., Setzer A.W. Risco de fogo da vegetação na América do Sul: comparação de três versões na  
estiagem de 2004. In: Simpósio Brasileiro de Sensoriamento Remoto (SBSR), 12., 2005, Goiânia. Anais... São  
José dos Campos: INPE, 2005. Artigos, p. 3349-3355. CD-ROM, On-line. ISBN 85-17-00018-8. Disponível em:  
<<http://marte.dpi.inpe.br/col/ltid.inpe.br/sbsr/2004/11.22.09.33/doc/3349.pdf>> Acesso em: 20 out. 2007.

Soares, R. V. Desempenho da fórmula de Monte Alegre: o índice brasileiro de perigo de incêndios florestais.  
*Revista Cerne*, v. 4 n.1 p.87-98.1998.

Soares, R. V. Determinação de um índice de perigo de incêndio para a região centro paranaense, Brasil.  
Dissertação (Mestrado em Engenharia Florestal), Centro Agronomico Tropical de Enseñanza e Investigacion,  
CATIE, Costa Rica. 1972.

Soares-Filho, B.S.; Nepstad, D.C.; Curran, L.M.; Cerqueira1, G.C.; Garcia, R.A.; Ramos, C.A.; Voll, E.;  
McDonald, A.; Lefebvre, P.; e Schlesinger. P. Modelling conservation in the Amazon basin. *Nature*, v. 440, n.  
7083, p.520-523, 2006.

# **SIMULATING FOREST FIRE RISK AND OCCURRENCE IN THE BRAZILIAN AMAZON**

Rafaella Almeida Silvestrini <sup>1</sup>  
Britaldo Silveira Soares-Filho <sup>1</sup>  
Hermann Rodrigues de Oliveira <sup>1</sup>  
Renato Assunção <sup>2</sup>  
Daniel Nepstad <sup>3</sup>

<sup>1</sup> Centro de Sensoriamento Remoto, Universidade Federal de Minas Gerais  
Av. Antônio Carlos, 6627, Belo Horizonte, Minas Gerais, 31270-900, Brazil

<sup>2</sup> Departamento de Estatística, Universidade Federal de Minas Gerais,  
Av. Antônio Carlos, 6627, Belo Horizonte, Minas Gerais, 31270-901, Brazil

<sup>3</sup> The Gordon and Betty Moore Foundation  
Presidio of San Francisco, P.O. Box 29910  
San Francisco, California 94129-0910

Correspondence: Rafaella A. Silvestrini, Britaldo Silveira Soares-Filho  
Tel: 55-31-3409-5449, Fax: 55-31-3409-5410  
E-mail: rafaufmg@yahoo.com.br, britaldo@csr.ufmg.br

## ABSTRACT

Fire models have become an important tool for assessing the resilience of forests in anthropogenic landscapes. A basic component of such models involves simulating the occurrence of fire ignition sources due to weather conditions and land-use practices. In this study, we have developed a model that simulates the occurrence of hot pixels, representing sources of fire within the Amazon forest and along its edges, based on the integration of climate and land-use data. The model was calibrated using NOAA-12 night satellite hot pixel data for 2003 and validated for the years 2002, 2004 and 2005. First, we used Weights of Evidence to estimate the influence of a series of spatial variables (e.g., proximity to roads, towns, and deforested areas, land-use zoning, and other biophysical factors) on the location of hot pixels. The resulting probability map was then combined with a climate probability map, derived from monthly VPD (vapor pressure deficit) data using logistic regression. Assessment of the integrated fire-risk probability map using ROC analysis yielded fitness values above 0.85 for all months of 2003. The model stochastically simulates the quantity and location of hot pixels, alternating (by dry and wet seasons) the coefficients used to average the probability maps and two density distribution functions employed to draw random numbers – the Beta (0.985, 0.1) and Weibull (13,0.6) distributions. Simulated hot pixels exhibited high overlap with the NOAA-12 hot pixel data both in terms of spatial and temporal distributions, showing a maximum yearly frequency deviation of 15%. As a result, the developed model can be used as an early alarm system for forest fire risk as well as to integrate simulations of future fire regimes in the Amazon in view of feedbacks between deforestation and climate, which eventually may lead the Amazon ecosystem into an irreversible cycle of deep impoverishment.

## 1. INTRODUCTION

Fire events play a major role in the dynamics of the Amazon Forest. Severe fires burned approximately 40 thousand km<sup>2</sup> in the northern Amazon, during 1997-98 El-Niño period (Nepstad *et al.* 1999a; Alencar *et al.* 2006). The advent of anthropogenically driven climate change predicts even more fires not only because of consequent longer dry seasons (Nobre *et al.* 1991; Mahli *et al.* 2008), but mainly due to the reduction of the intervals between extreme drought events (Cox *et al.* 2004; Marengo *et al.* 2008), which are the cause of the majority of large fires in the tropics. Aside from immediate disturbance effects that can cause a loss of up to 30% of the ecosystem's original complement of species (Slik *et al.* 2002), the negative consequences of a fire may last for many years. Tree mortality continues for at least two years (Holdsworth & Uhl 1997), and even after 15 years, forests indicate no signs of regaining lost species (Slik *et al.* 2002).

Forest fires also influence global warming. Alencar *et al.* (2006) estimated that annual carbon emissions from fires in the Brazilian Amazon may amount to 94±70 million of tons in ENSO years. However, this figure can be far surpassed in extreme El Niño years, such as the event of 1997-1998, when carbon emissions from forest fires in Mexico, the Amazon, and Indonesia reached 1.6 giga tons of carbon (Houghton *et al.* 2001) – the equivalent to 41% of the fossil fuel emissions worldwide. Beyond altering the composition of the atmosphere, forest fires interrupt normal atmospheric circulation processes, such as hydrological and cleaning processes (Ackerman *et al.* 2000), reducing rainfall (Andreae *et al.* 2004) and increasing the average residence time of smoke particles in the atmosphere (Ramanathan *et al.* 2001), thereby deeply impairing human health. For example, during the extreme drought that affected the southwestern Amazon in 2005 – probably associated with the abnormal warming of the tropical North Atlantic (Marengo *et al.* 2008) – over 40 thousand people in the State of Acre sought medical care due to a persistent smoke plume, which stemmed from multiple fires that burned 300 thousand hectares of forest in that region (Brown *et al.* 2006; Aragão *et al.* 2007).

During Pre-Columbian times, widespread fire events affected the Amazon forest at intervals of 400 to 700 years and were probably associated with extremely severe droughts (Meggers 1994). Currently, however, economic and demographic growth in the tropics, along with climate change, has shortened the frequency of these events to 5 to 15 years (Goldammer 1990; Cochrane *et al.* 1999; Alencar *et al.* 2006). As the agricultural frontier advances in the

Amazon region, the risk of wildfire increases since pasture and crop areas reduce evapotranspiration, contributing to lower humidity and acting as ignition sources due to land management practices that commonly involve fire (Nepstad *et al.* 2001). As a result, forest fires are more common along the forest edge (Laurance *et al.* 1997; Cochrane 2001; Alencar *et al.* 2004; Cochrane & Laurance 2002), not only because of fires that escape from pasture and crop burning practices, but also owing to drier climatic conditions on the neighboring deforested areas (Kapos *et al.* 1993; Gascon *et al.* 2000). In addition, extensive deforestation may lead to a reduction in the rainfall regime over the Amazon (Sampaio *et al.* 2007; Da Silva *et al.* 2008) augmenting the risk of loss of a large portion of the Amazon forest to climate change-induced fires as early as 2020 (Golding & Betts 2008).

In turn, logging favors forest fire by opening the canopy and thus increasing light penetration that lowers humidity and enhances forest flammability (Nepstad *et al.* 2001; Cochrane 2003). Similarly, fire begets more fire as it increases light penetration and initially adds more dry fuel to the forest floor (Nepstad *et al.* 2001).

Hence, the synergy between deforestation, logging, fire-friendly land management practices, and increasingly drier climate may spur recurrent widespread fire regimes in the Amazon, which will eventually lead remaining forests towards a cycle of deep impoverishment, a tipping point that may be reached within the next two decades (Nepstad *et al.* 2008; Golding & Betts 2008).

Despite the striking impact of fire on tropical forest ecosystems, fire modeling in the tropics is still at an early stage (Cochrane 2003). One of the major challenges for tropical fire modeling is the absence of data and models for fire fuels, which are crucial to predict the potential for ignition and duration of a fire (Cochrane 2003). Second, understanding of fire dynamics, and thus fire behavior in different types of fuels and environments, is still limited (Cochrane *et al.* 1999). Moreover, the only available basin-wide data for Amazon fires correspond to the hot pixels mapped from remote imagery (Cardoso *et al.* 2003). Hot pixel data present the disadvantage of not usually detecting understory fires (Nepstad *et al.* 1999b) and inability to measure the burned area (INPE 2008). In sum, wildfire models (e.g., Venevsky *et al.* 2002; NWGC 2002; CFS 2007) involve multiple components – i.e. ignition and propagation submodels –, comprising numerous parameters that still need to be adapted and calibrated to the biophysical characteristics of the various Amazon landscapes.

Nevertheless, some studies have attempted to develop models of fire risk for the Amazon. For example, Cardoso *et al.* (2003) analyzed climatic and biophysical variables to model the quantity of hot pixels on a 2.5° x 2.5° cell grid for the dry seasons of 1995 and

1997. Sismanoglu and Setzer (2005) developed a model to calculate the risk of fire for the entire Brazilian territory, taking into account climatic and vegetation variables processed at daily time steps and spatial resolution of 25x25 km. In turn, Nepstad *et al.* (2004) developed *RisQue*, a model that estimates PAW (Plant Available Water) as an indicator of forest fire risk for the entire Amazon basin. All these studies took advantage of an initiative conducted by CPTEC/INPE, which made hot pixel data collected daily by a series of satellites available on the Web ([www.cptec.inpe.br/queimadas](http://www.cptec.inpe.br/queimadas)).

To improve understanding of fire dynamics and its drivers, we have developed a model of forest fire risk for the entire Brazilian Amazon. The model presented here uses a probabilistic approach that integrates climate and land-use data to simulate monthly occurrences of hot pixels, representing ignition sources of fire within the Amazon forest and along its fringe (a buffer area of 4 km). As a result, the developed model has the potential to be applied as an early alarm system for forest fire risk as well as to integrate, as the ignition component, simulations of future fire regimes in the Amazon in the face of feedbacks between deforestation and climate.



## **2. MODEL DEVELOPMENT**

The present model estimates the probability of fire source by integrating climatic conditions, as described by VPD (Vapor Pressure Deficit) data, with a series of biophysical and land-use variables, such as elevation, distance to roads and towns, and legal restrictions – i.e. protected versus non-protected areas. The idea behind this approach is to combine the anthropogenic risk from land use with favorable weather conditions for fire. The model follows four steps. First, annual anthropogenic probability of fire, given a set of spatial variables, is obtained employing Weights of Evidence, a Bayesian method appropriate for modeling spatial data (Bonham-Carter 1994; Soares-Filho *et al.* 2004). Next, we developed a map of climatic risk by applying logistic regression on monthly VPD data. Subsequently, the two probability maps were merged into a single one using a weighted average. Finally, the model employed the combined probability map to stochastically simulate the quantity and location of hot pixels at monthly time steps and spatial resolution of 4 km<sup>2</sup>. Hot pixel data from 2003 were used to calibrate the model, given that the number of hot pixels for this year approximates the mean value for the analyzed time-period (1998-2005), and validation was conducted using data from 2002, 2004 and 2005. We developed all modeling phases using the Dinamica EGO graphical interface platform that handles multiple large map set and has special features for advanced spatial modeling and simulation (Soares-Filho *et al.* 2008a).

As fire is widely used to improve forage both in cultivated pastures and in native grasslands of Cerrado (Brazilian Savanna type vegetation), we avoid including this type of fire occurrence in our analyses, confining the hot pixel data to only forested areas and their neighboring buffers of 4 km. Therefore, our analyses only comprise fire sources that can reach the forest. The following sections describe in more details each step of the model development.

### **2.1. Anthropogenic risk of fire**

Previous studies have pointed out that fire occurrence relates spatially to logged and previous burned forests (Nepstad *et al.* 1999a), proximity to roads (Cardoso *et al.* 2003; Alencar *et al.* 2004), and forest edges (Alencar *et al.* 2004). On the other hand, protected areas greatly inhibit deforestation and fire (Nepstad *et al.* 2006b; Soares-Filho *et al.* 2008b). Of these various factors, we selected the following variables to compose the anthropogenic risk of fire: 1) distance to deforested or Cerrado areas; 2) distance to forest, 3) distance to towns, 4) distance to roads, and 5) elevation. These variables were selected because they showed low

spatial correlation to each other and due to their strong spatial association with fire occurrence as pointed out by the Weights of Evidence analysis. The cartographic dataset employed in this work comes from various sources. Elevation is derived from SRTM maps, towns from IBGE data, forest and deforested areas from PRODES (INPE 2008), and roads and protected area from UFMG in-house compiled datasets.

Weights of Evidence is a Bayesian method traditionally used to derive favorability maps for spatial point phenomena (Agterberg & Bonham-Carter 1990; Bonham-Carter 1994). In this study, weights of evidence ( $W_k^+$ ) are calculated for every  $k$  category of each spatial variable under analysis and can be interpreted as the influence of that category on the chances of occurring a hot pixel. Since this method only applies to categorical data, it is necessary to categorize continuous gray-tone variables, such as distance-decay maps; this is done using a method adapted from Agterberg and Bonham-Carter (1990) in Dinamica EGO (Soares *et al.* 2008a).

Given a set of spatial variables  $A, B, C, \dots, N$ , the probability of a hot pixel is denoted as follows:

$$P(HotPixel | A \cap B \cap C \cap \dots \cap N)_{(x,y)} = \frac{e^{\sum_{k=1}^n W_k^+_{(x,y)}}}{1 + e^{\sum_{k=1}^n W_k^+_{(x,y)}}} \quad (1)$$

where

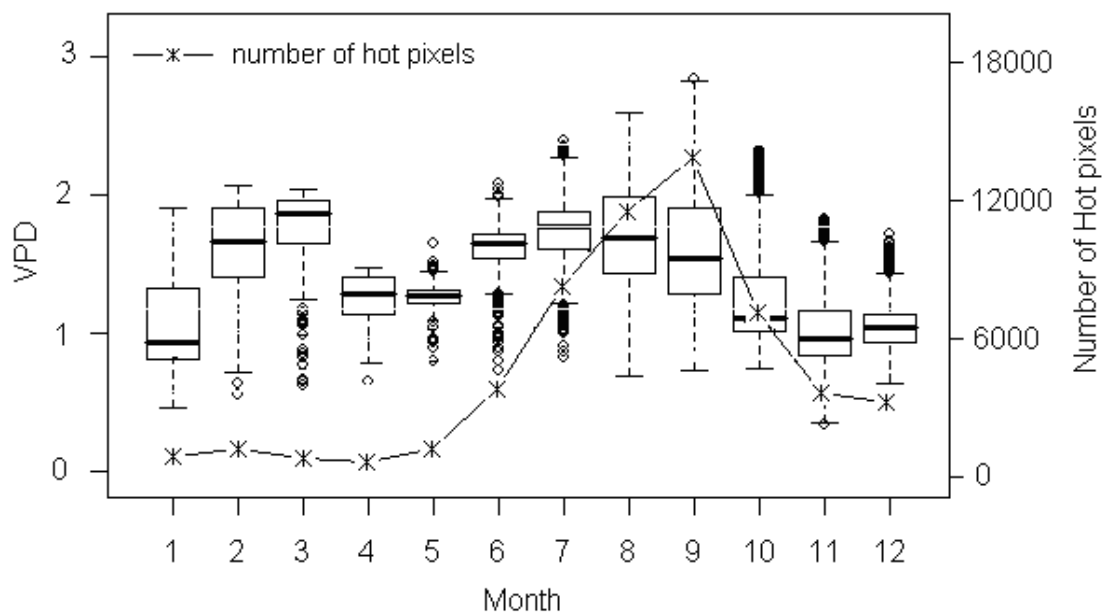
$$W_k^+ = \ln \left( \frac{P(B_k | HotPixel)}{P(B_k)} \right) \quad (2)$$

$P(hotPixel | A \cap B \cap C \cap \dots \cap N)_{(x,y)}$  is the probability for a hot pixel to occur given the explanatory variables  $A, B, C, N$  at a cell location  $(x,y)$  and  $W_k^+$  is the weight of evidence coefficient for a category  $k$  of a variable  $B$ . High positive values for weights of evidence favor the modeled event: the higher the value, the stronger the association. On the other hand, a negative  $W_k^+$  value indicates an inhibitory effect, whereas values close to zero show no effect at all (Bonhan-Carter 1994). The only assumption of this method is that all variables be independent. In order to test this assumption, we measured the correlation between pairs of variables applying the Joint Information Uncertainty test (Bonhan-Carter 1994). In addition, the explanatory power of each variable was evaluated by comparing the weights of evidence contrast ( $W_k^+ - W_k^-$ ) for each of the variable categories, so that the most significant variables showed the highest contrasts and thus the strongest relation with hot pixel location.

The probability map is calculated integrating all the  $W_k^+$  by means of equation (1). As new roads are built, deforestation advances and new protected areas are created; this map is updated on an annual basis by employing either observed data or outputs from simulation of Amazon deforestation, which integrates scenarios of public policies, infrastructure development, and demand for agricultural products (Soares-Filho *et al.* 2006; Soares-Filho *et al.* 2008b). In the following sections,  $P(\text{hotPixel}|A \cap B \cap C \cap \dots \cap N)_{(x,y)}$  for a year  $j$  will be referred to as  $Pbiop_{(x,y),j}$ .

## 2.2. Climatic risk of fire

Previous studies have applied to modeling fire risk variables such as precipitation, temperature, relative humidity (Cardoso *et al.* 2003; Sismanoglu & Setzer 2005), and PAW (Nepstad *et al.* 2004). Nevertheless, in this study we selected vapor pressure deficit (VPD) as the sole explanatory variable for modeling the influence of climate seasonality on hot pixel occurrence. VPD is a combination of temperature and relative humidity, consisting of monthly means acquired from a varying number of 266 meteorological stations over the Amazon and interpolated into monthly maps from 1995 to 2005 at a grid resolution of 8x8 km (Hirsch *et al.* 2004). We chose VPD for three reasons. First, boxplot graphs with monthly values of VPD from hot pixels (Figure 1) showed a strong positive association between these two variables. Second, as VPD is correlated to other climatic variables commonly applied to fire modeling, such as precipitation, PAW and relative humidity itself, only one of them could be employed in the logistic regression analysis; the best fit was obtained when VPD was used



**Figure 1:** Boxplot of VPD and number of hot pixels for 2003.

alone (Table 1). Third, Ray *et al.* (2005) have shown that internal forest VPD, which can be derived from meteorological VPD, is a good indicator of forest flammability.

**Table 1:** Observed and predicted values using the regression mean values for 2003 in the climatic probability risk equation.

Predicted	Observed	Jan	Feb	Mar	Apr	May	Jun	July	Aug	Sept	Oct	Nov	Dec
1	1	16%	38%	38%	21%	34%	39%	65%	61%	57%	14%	16%	8%
1	0	7%	6%	5%	8%	9%	15%	12%	13%	15%	19%	51%	5%
0	1	24%	3%	2%	19%	6%	1%	1%	6%	9%	26%	7%	43%
0	0	53%	54%	56%	52%	51%	46%	21%	20%	18%	41%	27%	45%
Total correct classification		69%	91%	94%	74%	85%	85%	87%	81%	76%	55%	42%	53%

As climate seasonality differs in the northern and southern hemispheres, we had to develop a general model that could describe the climatic risk for fire on a monthly basis throughout the year and across the entire Amazon. Therefore, we tested different approaches to derive a single relation that could be applied to all different regions and seasons. The best approach consisted in adjusting a separate logistic regression for each month, in which the response variable is the hot pixel and the explanatory variable is the monthly mean VPD as follows:

$$Pcl_{(x,y),i,j} = \frac{e^{\beta_{0i} + \beta_{1i} * VPD_{(x,y),i,j}}}{1 + e^{\beta_{0i} + \beta_{1i} * VPD_{(x,y),i,j}}} \quad (3)$$

where  $Pcl_{(x,y),i,j}$  represents the probability of a hot pixel given VPD at cell  $(x,y)$  in month  $i$  and year  $j$ , and  $\beta_{0i}$  and  $\beta_{1i}$  are the parameters of the logistic regression for month  $i$ . By replacing the  $\beta_{0i}$  and  $\beta_{1i}$  values with the 2003 mean values, we obtain the formula expressed below, which is the general equation used to calculate the monthly climatic risk for the time-series under analysis.

$$Pcl_{(x,y),i,j} = \frac{e^{-5.08196 + 4,10052 * VPD_{(x,y),i,j}}}{1 + e^{-5.08196 + 4,10052 * VPD_{(x,y),i,j}}} \quad (4)$$

### 2.3. Integrating anthropogenic and climatic risks

Forest fire risk is a combined effect of anthropogenic factors with favorable weather conditions. Hence, our approach consisted in merging both anthropogenic and climatic risk maps into one. After testing several approaches to generate a probability of fire that accounted for both biophysical and climatic factors (e.g., combining the two probability maps using the Weights of Evidence method or through geometric averaging), we chose to weight average the two maps using different weight values according to the seasons of the year (equation 5), given that this method yielded the highest ROC indices – Relative Operating Characteristic (Pontius & Schneider 2001).

$$P_{(x,y),i,j} = \alpha_i * P_{biop_{(x,y),j}} + (1 - \alpha_i) * P_{cl_{(x,y),i,j}} \quad (5)$$

where  $P_{(x,y),i,j}$  is the combined probability for hot pixel at a cell  $(x,y)$  in month  $i$  of year  $j$ .  $P_{biop_{(x,y),i,j}}$  is the probability of fire given a set biophysical factors at year  $j$  and  $P_{cl_{(x,y),i,j}}$  represents the probability of fire given climatic conditions for month  $i$  of year  $j$ .  $\alpha$  value assumes 0.2 from January to April and 0.4 for the other months. In essence, this set of value relates loosely to the dry and wet seasons in the Amazon, which experiences alternate seasons above and below the equator. Furthermore,  $\alpha$  values suggest that the climatic probability accounts more for fire risk, possibly because human induced fires only occur when weather conditions are favorable.

### 2.4. Hot Pixel Simulation

The developed model stochastically simulates the occurrence of hot pixels at monthly time-steps using the combined fire-risk probability map and taking into account the spatial and temporal dependence between hot pixels. The spatial dependence between fire events has already been considered for predicting fire occurrences (Sismanoglu & Setzer 2005). In this work, we tested the spatial dependence between hot pixels for each month of 2003 by means of Moran's Autocorrelation Index, which was normalized to a  $\{-1,1\}$  interval to facilitate interpretation (Bailey & Gatrell 1995). The Moran's Autocorrelation Index indicates the extent to which the occurrence of a hot pixel influences the occurrence of another one in neighboring cells. The values obtained from this test were significant, as pointed out by the  $p$ -value, demonstrating a positive dependence between nearby hot pixels, in particular for the dry season months (Table 2). Hence, this effect must be incorporated into the model as described below.

**Table 2:** Adjusted Moran's autocorrelation index and respective p-values for 2003 hot pixels

Month	Moran's index value	p-value
January	0.139	0.003
February	0.305	0.002
March	0.221	< 0.001
April	0.215	0.002
May	0.294	< 0.001
June	0.386	< 0.001
July	0.392	< 0.001
August	0.316	< 0.001
September	0.283	< 0.001
October	0.245	0.002
November	0.179	0.002
December	0.229	0.003

The next step consisted in identifying the probability density function of the modeled event, a standard procedure for developing stochastic simulations. The density function of the monthly fire risk maps for 2003 hot pixels showed that the probability functions from January to September matched a Beta (0.985;0.1) distribution truncated at 0.5, while those from October to December approximated a Weibull(13;0.6) distribution. As a result, these distributions were employed to draw random numbers for the cell selecting mechanism so that for each cell, a hot pixel would occur if:

$$\left(\rho_{(x,y),i,j} - \gamma_i\right) < P_{(x,y),i,j} < \left(\rho_{(x,y),i,j} + \gamma_i\right) \quad (6)$$

where  $P_{(x,y),i,j}$  is the probability of hot pixels;  $\rho_{(x,y),i,j}$  corresponds to a random number drawn from the probability density function according to month  $i$  of year  $j$  for the  $(x,y)$  cell and  $\gamma_i$  is a constant (Table 3) used to control the number of simulated hot pixels by increasing the acceptance interval.

**Table 3.**  $\gamma$  values

Months ( $i$ )	$\gamma_i$
January to April and October to December	0.05
May to September	0.09

In order to incorporate the spatial and temporal dependences between hot pixels, the selecting cell process was divided into 10 loops – each one analyzing only 10% of the quantity of cells so that after the tenth iteration the whole map has been completely analyzed.

After each loop, the spatial dependence is incorporated into the model, multiplying the probability of neighboring cells (considering a Moore neighborhood of 8 adjacent cells) of simulated hot pixels by 1 plus the Moran Index of the corresponding month (Table 2) and limiting the maximum probability value to 0.9999 to avoid probabilities equal or greater than 1.

Because the number of hot pixels is dependent on the map resolution, the last procedure within the loop consists of sampling only a percentage of selected cells to become simulated hot pixels by applying a pruning factor according to Table 4.

**Table 4.** Simulated hot pixel pruning factors

Months ( <i>i</i> )	
January to May	0.995
June, July and October to December	0.999
August and September	0.997

## 2.5. Model validation

We validated the model comparing its results to the observed data for 2002, 2004, and 2005 on a monthly basis. For this purpose, we applied three fitness measures. One is the Relative Operating Characteristics – ROC (Pontius & Schneider 2001). ROC statistics measure the level of agreement between a probability or favorability map and a map with the observed events, in this case the actual hot pixel map. Value 1.0 means a perfect match, whereas values around 0.5 can be expected due to chance.


The second method applies a fuzzy map comparison between the monthly simulated and the observed hot pixels (Soares-Filho *et al.* 2008a; Almeida *et al.* 2008). This method compares the number of cells of a certain class in a simulated map with the number of these cells in a reference map that fall within a central cell neighborhood, as defined by a window size. By using a constant decay function, if a matching cell is found within the window, fit is assigned to 1, otherwise 0. Windows with increasing sizes convolute over the map and a mean is computed for each window size. This method employs a reciprocal approach, comparing the match between map 1 to map 2, and vice versa, ultimately choosing the minimum mean in order to penalize random maps, which tend to overestimate the fit. In this manner, this method accounts for both omission and commission errors. Our comparison employed increasing windows sizes from 1 to 11 cells, which in terms of map resolution represent a range of

22x22 km. Finally, the third method compared the monthly quantity of simulated hot pixels with that of observed ones through time-series graphs.



### 3. RESULTS

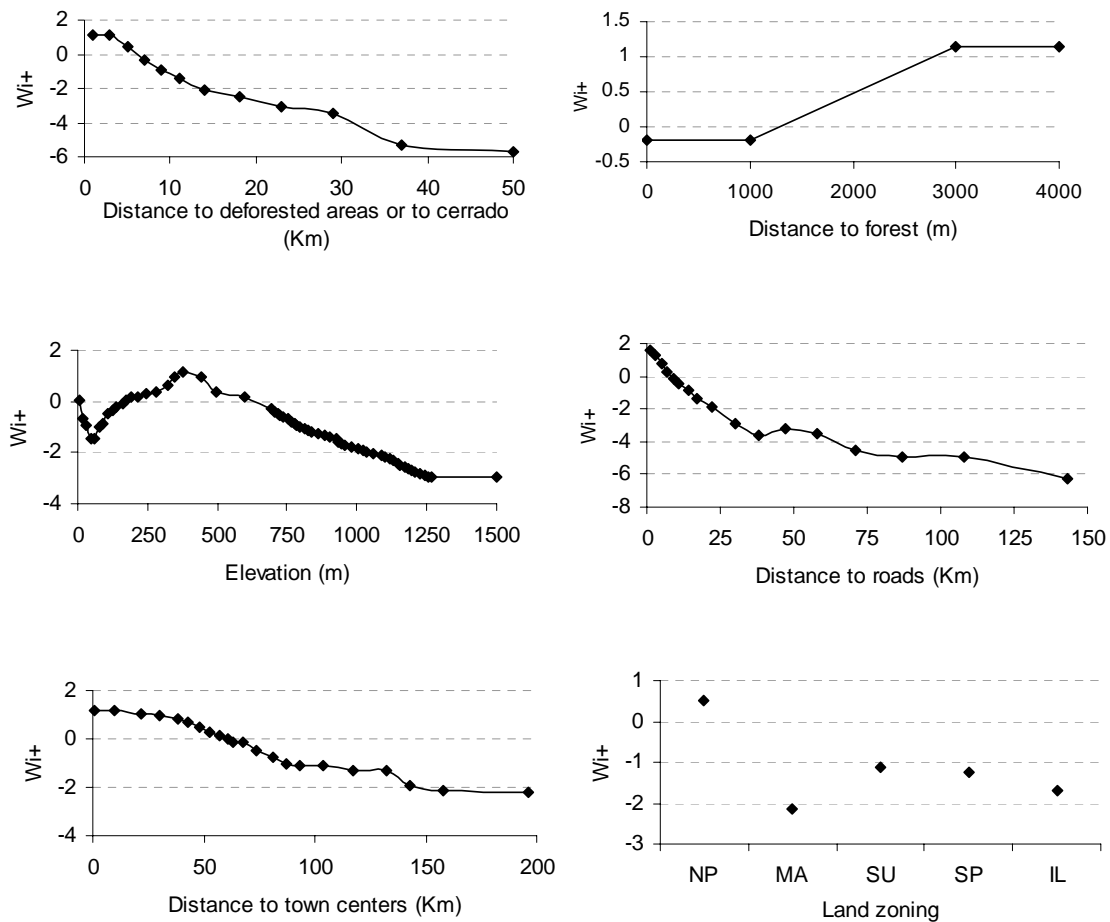
Figure 2 shows fire risk for 2004 given the selected set of biophysical and land-use variables. The risk map indicates a strong inhibitory effect of protected areas on hot pixel density, as already pointed out by Nepstad *et al.* (2006a). Conversely, hot pixels closely follow deforestation and major roads, such as the BR-163 (Cuiabá-Santarém), the BR-319 in Acre, and Transamazonica (Figure 2 – a, b, and c) highways, demonstrating the strong association of fire with forest clearing and pasture maintenance practices.



**Figure 2:** Risk of fire given biophysical variables for 2004. The highways are represented by: a) BR-163 (Cuiabá-Santarém); b) the BR-319 in Acre; and c) Transamazonica.

Figure 3 depicts the spatial function for each one of these factors alone. Positive weights of evidence for forest near deforested areas highlight the major effect of forest fragmentation in facilitating forest fire (Alencar *et al.* 2004). In accordance with previous studies (Laurance *et al.* 2001; Cardoso *et al.* 2003), proximity to roads is another high risk factor, showing that forests located within 8 km or less from roads are highly vulnerable to fire. Distance to town centers showed a similar effect, although with lower absolute values. A negative association between hot pixels and elevation appears up to 70m, probably related to flooded plains and wetlands. From 70 to 690 m the chance of fire tends to increase, as land becomes *terra firme* (non-flooded land), then from 700m upwards, this tendency reverses again. Notably, the protected area network greatly controls the spatial distribution of hot pixels, showing a strong inhibitory effect as depicted by the probability map and their

negative weights of evidence; the weights of evidence for protected areas exhibit the lowest values for indigenous lands and military areas.




**Figure 3:** Weights of Evidence ( $W^+$ ) graphs for the variables: a) distance to deforested areas or to Cerrado; b) distance to forest; c) elevation; d) distance to roads; e) distance to towns; f) Land zoning: NP - Non Protected; MA, military area; SU Sustainable Use; SP - Strict Protection; and IL - Indigenous Land.

In addition, seasonal patterns of climate across the Amazon control the risk for fire (Figure 4). In the early months of the year, the dry season is located north of the equator, where fire risk becomes high. As the year unfolds, the high probability zone moves southward and expands itself until it reaches a maximum in August. Then, at the beginning of rainy season in the southern hemisphere, in October, this zone moves toward the Northeast, confining itself again to the North of the Amazon at the end of the year. This pattern is repeated in annual cycles with the high-risk zone becoming larger and more persistent in years of severe drought. A cross-tabulation of observed versus predicted hot pixels from the monthly logistic regressions (Table 1) show that VPD can better predict fire risk during the dry season months and February and March, which showed especially high accuracy scores.

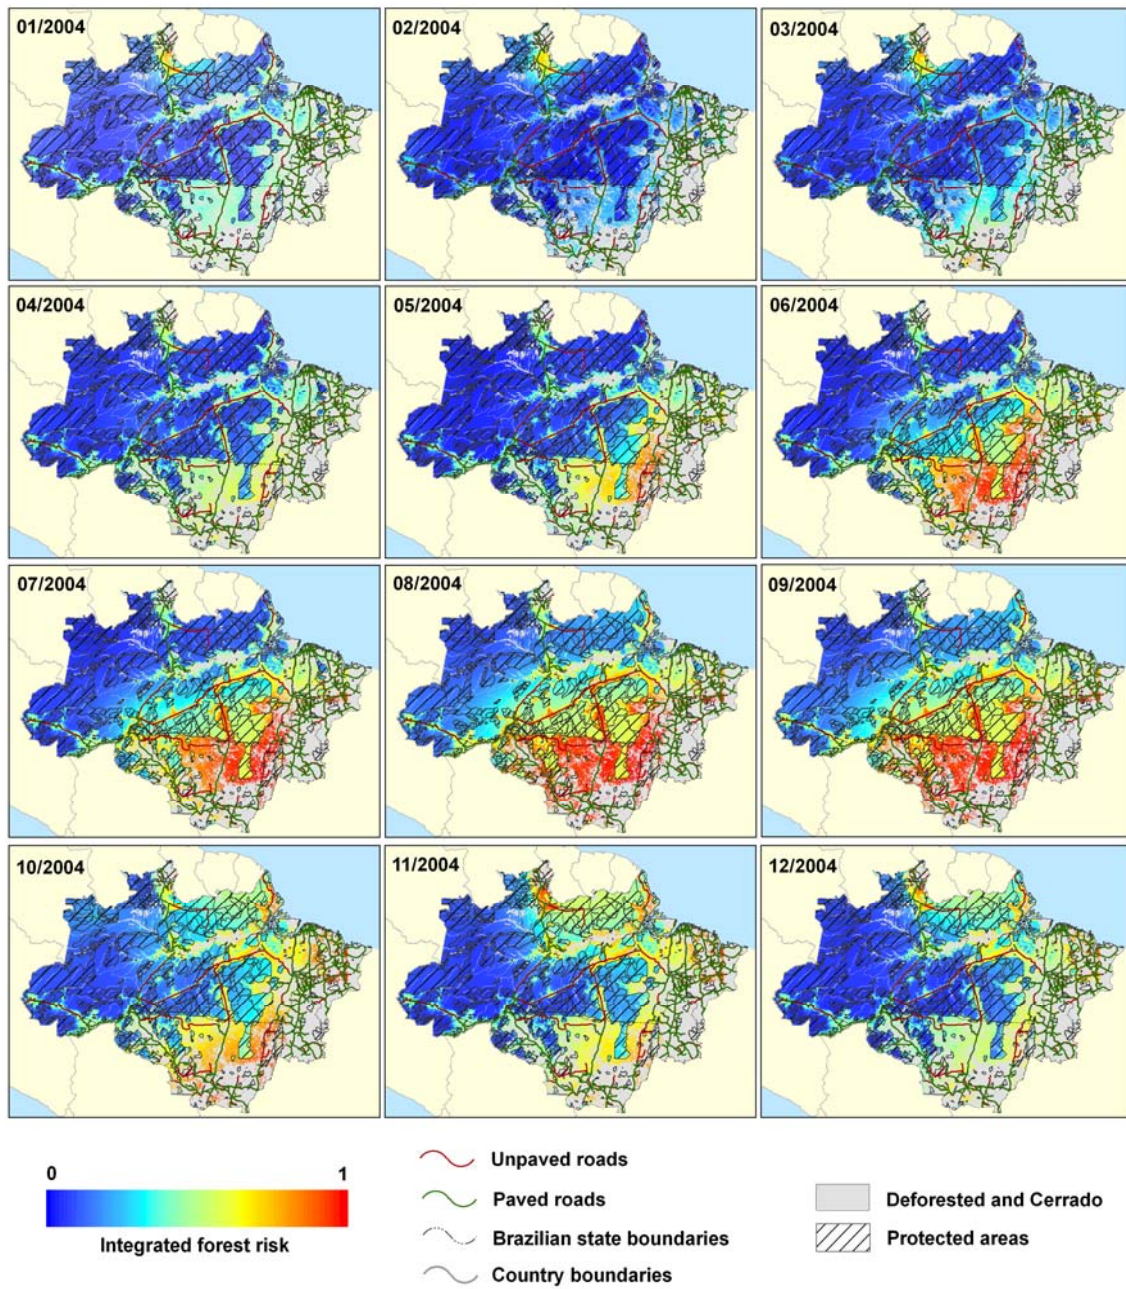
The combined map of fire risk follows the same temporal pattern as the climatic risk more the details added by the anthropogenic risk (Figure 5). A comparison of the monthly probability maps with their corresponding hot pixel maps using ROC yielded values over 0.85 for all years, thus demonstrating their likelihood in revealing the zone of high risk for fire. This prediction is more accurate from February to June, in contrast to the period from October to December (Figure 6).

With respect to the simulation of hot pixels, even though spatial dependence was incorporated into the model, the observed hot pixels are still more clustered than the simulated ones in all months (Figure 7). Nevertheless, the agreement between the two maps, as measured by the Fuzzy Map comparison, achieved a match of 60-70% in September within a window size of 11 by 11 cells (resolution of 22 by 22 Km) (Figure 8). Again, the driest months of the Southern hemisphere, June to September, and also February and March, showed the highest degree of agreement between observed and simulated hot pixels, whereas the model performed more poorly from October to January.


In terms of quantity, the number of simulated hot pixels follows the same temporal monthly distribution as the observed ones (Figure 9), showing a maximum annual deviation of 15%. In general, the model tends to overestimate the quantity of hot pixel cells in August, September and October, whereas it underestimates the quantity in the other months.



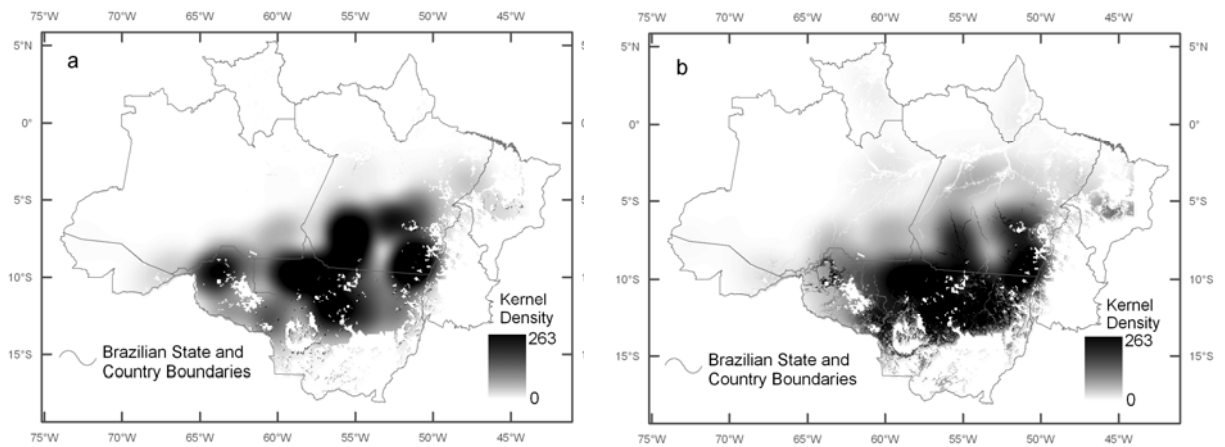
**Figure 4:** Monthly climatic fire risk for 2004.




**Figure 5:** Monthly integrated fire risk for 2004.



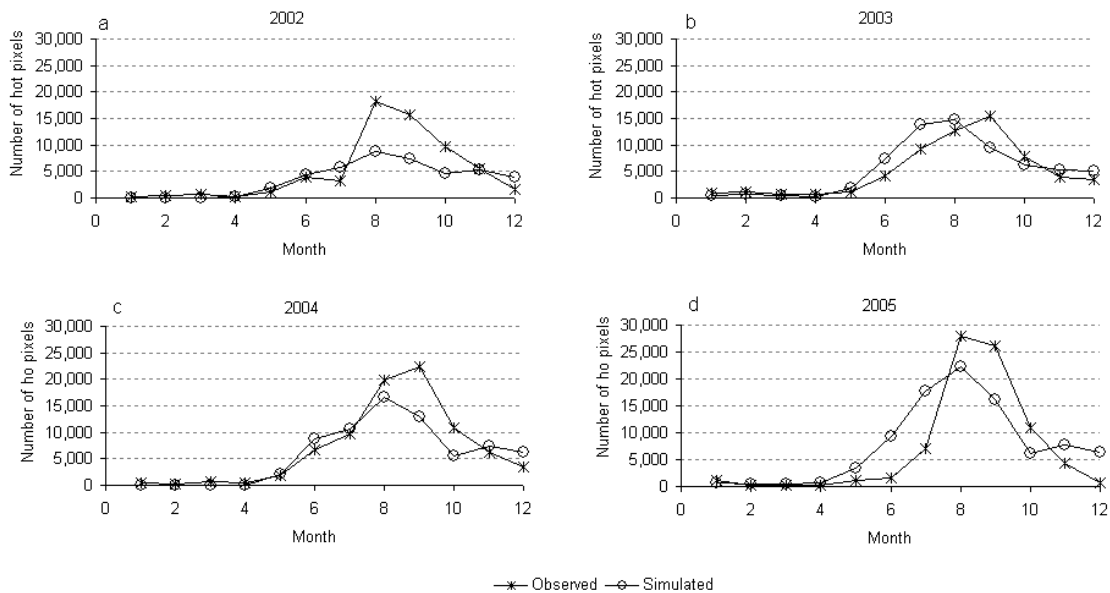
**Figure 6:** ROC statistics for the probability maps of fire from 2002 to 2005.



**Figure 7:** Kernel Density for a) observed hot pixels and b) simulated hot pixels for August, 2004.



**Figure 8.** Model fitness according to the Fuzzy Similarity method for 2002 (A), 2003 (B), 2004 (C) and 2005 (D).



**Figure 9:** Time series graphs of observed and simulated hot pixels for for 2002 (A), 2003 (B), 2004 (C) and 2005 (D).

#### 4. DISCUSSION

In this study, we have developed a probabilistic approach for estimating the occurrence of hot pixels in the Brazilian Amazon forest, given a set of biophysical and land-use variables plus VPD data. It is important to note that the majority of modeled hot pixels do not represent understory fires (Nepstad *et al.* 1999b), but slash-burn, forest clearing, or pasture maintenance practices. However, due to their proximity to the forest, they could represent major sources of fires that tend to escape towards the remaining forest and extend within it for several kilometers, such as the fires that burned in Acre in 2005 (Aragão *et al.* 2007). In this sense, the model presented here was conceived as an ignition source component for modeling fire. Still, more detailed land-use maps, which include not only forest and deforested classes, but differentiation between ranching and crop farming and large properties from small landholders, will increase the accuracy of modeling the source of forest fires, given that fire practices are highly associated with land management practices (Alencar *et al.* 2006), and thus relatively more absent in regions with a greater concentration of agro-industrial annual crop production (D. Nepstad, unpublished data). In addition, increasing the density of the regional meteorological station grid will allow the model to perform better at finer spatial resolutions. However, at this stage, there is no need to increase the model resolution, since validation showed that model spatial fitness only reaches 60 to 70% as spatial resolution decreases beyond 20x20 km. Nevertheless, in terms of assisting a fire-preventing program, this spatial radius is readily accessible to local fire brigades. Moreover, due to the way cells are stochastically selected by the model, the number of simulated hot pixel cells becomes highly dependent on the map cell resolution. As we double model resolution, we need to increase the sampling factor used to pruning hot pixel cells in the simulation process by powering it to two.

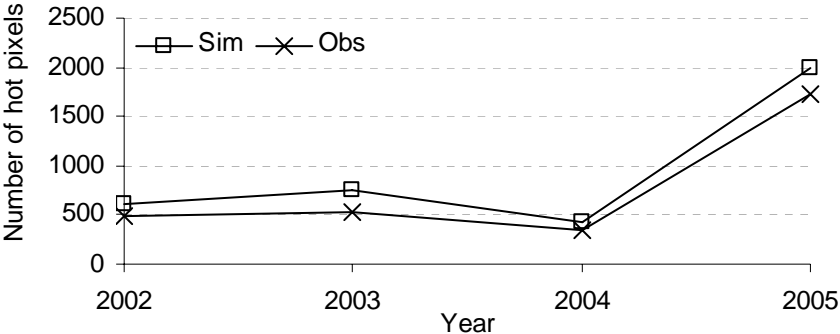
Therefore, we must take into account that the present model represents a step towards a thorough fire ignition-propagation model. In contrast to the coarse-resolution approach of land surface-climate models (e.g., Kucharik *et al.* 2000; Delire *et al.* 2004; Gordon *et al.* 2000), this type of model needs a finer scale (< 500 m or less) to be able to incorporate terrain features, such as land-use barriers, down and up slopes, river channels as well as local prevailing wind directions. Still, a fire propagation model must include fuel-load dynamics in order to simulate fire spreading and duration in different environments and weather conditions as well as to incorporate feedbacks between forest disturbance events, such as logging and recurrent fires. For example, experiments in the Xingu headwaters indicate that after a fire,



the chances of additional fires at the same place in the next two years increase, however, in the third year, fire spread is constrained by insufficient fuel loads (Balch *et al.* 2008).

In general, fine scale versions of fire models adopt a process-based approach (e.g., Rothermel 1972; Albini 1996; Butler *et al.* 2004; Cruz *et al.* 2005, 2006), which requires the calibration of numerous parameters that describe the physics of fire, such as wind profile, energy transfer, fuel conditions, topography, flame depth and height. However, the design of such a model for the various Amazon landscapes could become an insurmountable task due to the lack of calibrated equations and data for modeling the physics of fire in tropical environments. Instead, a more straightforward approach consists of adopting a probabilistic framework similar to the one presented here to model the relationship between the state of the forest and fire behavior. As this approach is data driven, it can easily incorporate new observational data supplied by field experiments as well as take advantage of heuristic calibration methods, such as genetic algorithms (Kosa 1992) and neural networks (Haykin 1999), which are becoming increasingly more user-friendly.

In sum, our approach consisted of developing a general model that could perform well for the entire Brazilian Amazon, pinpointing the high-risk areas for fire in response to land-use and climate seasonality as well as its annual variability. The model’s ability to simulate the abnormally higher density of hot pixels in the southwestern Amazon in 2005, in close association with the widespread fires of that particular year, lends support to its applicability for fire risk prediction (Figure 10). In comparison to previous models of fire risk for the Amazon, our model is the first one to be thoroughly validated and to include the inhibitory effect of protected areas as well. Nevertheless, it is expected that forthcoming availability of monthly basinwide maps of forest fire scars will allow the refinement of the present model of forest fire risk ([www.cptec.inpe.br/queimadas](http://www.cptec.inpe.br/queimadas)).



**Figure 10:** Time series graphs of observed and simulated hot pixels for the state of Acre.

## 5. CONCLUSION

Climate model experiments predict a large-scale substitution of Amazon forest by savanna-like vegetation ecosystems by the end of the 21<sup>st</sup> Century in response to global warming (Oyama & Nobre 2003; Botta & Foley 2002; Cox *et al.* 2000, 2004). Expanding global demands for agriculture products and biofuels (Nepstad *et al.* 2006a; Nepstad *et al.* 2008) together with infrastructure investments in the Amazon (Carvalho *et al.* 2001) may push the agriculture frontier and the timber industry faster and further into the core of the Amazon region (Soares-Filho *et al.* 2006; Nepstad *et al.*, 2008; Merry *et al.*, in press). As a result, positive feedbacks in the forest fire regime due to deforestation, logging and climate change may drive a rapid process of forest degradation that could lead the Amazon ecosystem into an irreversible cycle of deep impoverishment (Nepstad *et al.* 2008). However, climate-vegetation simulations that include land-use change and the synergistic effects of land-use change and regional climate change on a changing Amazon fire regime are still incipient (Golding & Betts 2008). Therefore, the present model represents a step towards an integrated model that aims to prospect the likelihood of a near-term forest dieback tipping point due to the complex interactions between deforestation, logging, fire and climate change in the Amazon. In addition, this model has the potential to measure impacts from forest degradation, such as carbon emissions from fire, an important component of REDD (Reduced Emissions from Deforestation and Forest Degradation) - a proposal to compensate developing countries for reducing emissions from deforestation and forest degradation currently under negotiation at UNFCCC (United Nations Framework Convention on Climate Change) meetings.

## 6. ACKNOWLEDGMENTS

The authors thank the Betty and Gordon Moore Foundation, the Packard Foundation, *Conselho Nacional de Desenvolvimento Científico e Tecnológico* – CNPQ, and the Large-Scale Biosphere Atmosphere Experiment (LBA-ECO) for funding. We also gratefully acknowledge the contributions of Claudia Sticker for revising the English and Dr. Albert Seltzer for his comments and for making the hot pixel data available on the Web.

## REFERENCES

- Ackerman, AS, Toon OB, Stevens DE, Heymsfield AJ, Ramanathan V, Welton EJ (2000) Reduction of tropical cloudiness by soot. *Science* **288**, 1024–1047
- Agterberg, FP, Bonham-Carter, GF (1990) Deriving weights of evidence from geoscience contour maps for the prediction of discrete events. XXII Int. Symposium AP-COM, 381-395
- Albini FA (1996) Iterative Solution of the radiation transport equations governing spread of fire in wildland fuel. *Fizika Goreniya i Vzriva* **32** (5), 71-82.
- Alencar A, Solorzano LA, Nepstad DC (2004) Modeling forest understory fires in an eastern Amazonian landscape. *Ecological Applications*, **14** (4), S139–S149
- Alencar A, Nepstad DC, Vera Diaz MdC (2006) Forest understory fire in the Brazilian Amazon in ENSO and non ENSO years: Area burned and committed carbon emissions, *Earth Interactions*, **10**, 1-16
- Almeida, C, Gleriani, Castejon, Soares Filho BS (2008) Neural networks and cellular automata for modeling intra-urban land use dynamics. *International Journal of Geographical Information Science*, **22** (9), 943-963.
- Andreae MO, Rosenfeld D, Artaxo P, Costa AA, Frank JP, Longo KM, Silva-Dias MAF (2004). Smoking rain clouds over the Amazon. *Science* **303**, 1337-1342.
- Aragão LE, Malhi Y, Roman-Cuesta RM, Saatchi S, Anderson LO, Shimabukuro E (2007) Spatial patterns and fire response of recent Amazonian droughts. *Geophysical Research Letters*, **34**, L07701.
- Bailey TC, Gatrell AC (1995) Interactive Spatial data Analysis. Longman, New York.
- Balch, JK, Nepstad DC, Brando PM et al (2008) Negative fire feedback in a transitional forest of Southeastern Amazonia. *Global Change Biology*, **14**,1-12.
- Bonham-Carter G (1994) *Geographic information systems for geoscientists: modelling with GIS*. Pergamon, 398 pp.
- Botta A, Foley JA. (2002). Effects of climate variability and disturbances on the Amazonian terrestrial ecosystems dynamics. *Global Biogeochemical Cycles* **16** (11), 1070, doi:10.1029/2000GB001338.

- Brown IF, Schroeder W, Setzer A, Maldonado MdLR, Pantoja N, Duarte A, and Marengo JA (2006) Monitoring fires in Southwestern Amazonia rain forests. *Eos* **87**, 253-264.
- Butler BW, Finney MA, Andrews PL, Albini FA (2004) A radiation driven model for crown fire spread. *Canadian Journal of Forest Research*, **34**, 1588-1599.
- Cardoso MF, Hurtt CG, Moore B, Nobre CA, Prins EM (2003) Projecting future fire activity in Amazonia. *Global Change Biology*, **9**, 656 – 669
- Carvalho G, Barros AC, Moutinho P, Nepstad D (2001) Sensitive development could protect Amazonia instead of destroying it. *Nature*, 409, 131.
- CFS, 2007. Canadian Forest Service. Canadian Forest Fire Danger Rating System (CFFDRS) Available at: <http://fire.cfs.nrcan.gc.ca/>
- Cochrane MA (2001) Synergistic interactions between habitat fragmentation and fire in evergreen tropical forests. *Conservation Biology*, **15** (6), 1515–1521.
- Cochrane MA (2003) Fire Science for rainforests. *Nature*, **421**, 913-919.
- Cochrane MA, Alencar A, Schulze MD et al. (1999) Positive feedbacks in the fire Dynamic of closed canopy tropical forests. *Science*, **284**, 1832–1835.
- Cochrane MA, Laurance WF (2002) Fire as a largescale edge effect in Amazonian forests. *Journal of Tropical Ecology*, **18**, 311–325.
- Constanza R. (1989) Model goodness of fit: a multiple resolution procedure. *Ecological Modelling*, **47**, 199-215.
- Cox PM, Betts RA, Collins M, Harris PP, Huntingford C, Jones CD (2004) Amazonian forest dieback under climate-carbon cycle projections for the 21st century. *Theoretical and Applied Climatology*, **78**, 137-156.
- Cox, PM, Betts RA, Jones CD, Spall SA, Totterdell IJ (2000) Acceleration of global warming due to carbon-cycle feedbacks in a coupled climate model. *Nature*, **408**, 184.

Cruz MG, Alexander ME, Wakimoto RH (2005) Developing and testing of models for predicting crown fire rate of spread in conifer forest stands. *Canadian Journal of Forest Research*, **36**, 1626-1639.

Cruz GC, Butler BT, Alexander ME, Forthofer JM, Wakimoto RH (2006) Predicting the ignition of crown fuels above a spreading surface fire. Part I: model idealization. *International Journal of Wildland Fire*, **15**, 47-60.

Da Silva RR, Werth D, Avissar R (2008) Regional Impacts of Future Land-Cover Changes on the Amazon Basin Wet-Season Climate. *Journal of Climate*, **21** (6), 1153-1170

Delire C, Jonathan A, Foley and Thompson S (2004) Long-term variability in a coupled atmosphere-biosphere model. *Journal of Climate*, **17** (13), 3947- 3959.

Gascon C, Williamson GB, Fonseca GAB (2000) Receding forest edges and vanishing reserves. *Science*, **288**, 1356–1358.

Goldammer JG (1990) Fire in the Tropical Biota pp 487–489. Springer, Berlin.

Golding N, Betts R (2008) Fire risk in Amazonia due to climate change in the HadCM3 climate model: Potential interactions with deforestation *Global biogeochemical cycles*, **22** GB4007, doi:10.1029/2007GB003166.

Gordon C, Cooper C, Senior CA, *et al* (2000) Simulation of SST, sea ice extents and ocean heat transport in a version of the Hadley Centre coupled model without flux adjustments. *Climate Dynamics*, **16**, 147–168.

Haykin SS (1999) *Neural Networks: A Comprehensive Foundation* (Upper Saddle River, NJ: Prentice-Hall).

Hirsch AI, Little WS, Houghton RA, Scott NA, White JD (2004) The Net Carbon Flux Due to Deforestation and Forest Re-Growth in the Brazilian Amazon: Analysis Using a Process-Based Model. *Global Change Biology*, **10**, 908-924.

Holdsworth AR, Uhl C (1997) Fire in Amazonian selectively logged rain forest and the potential for fire reduction. *Ecological Applications*, **7**, 713–725.

Houghton JT, Ding Y, Griggs DJ *et al.* (2001) Climate Change 2001: The Scientific Basis. In: *Contribution of Working Group I to the Third Assessment Report of the Intergovernmental Panel on Climate Change*. Cambridge University Press, Cambridge, UK.

INPE (2008) O Monitoramento de Queimadas em Tempo Quase-Real do INPE. Perguntas Frequentes. Available at <http://sigma.cptec.inpe.br/produto/queimadas/queimadas/perguntas.html>

Kapos V, Ganade G, Matsui E, Victoria RL (1993).  $d^{13}C$  as an indicator of edge effects in tropical rainforest reserves. *Journal of Ecology*, **81**, 425–431.

Koza JR (1992) *Genetic Programming: on the programming of computer by means of natural selection - Complex Adaptive Systems*. MIT press, 840 pp.

Kucharik CJ, Foley J, Delire C *et al.* (2000) Testing the performance of a dynamic global ecosystem model: Water balance, carbon balance, and vegetation structure. *Global Biogeochemical Cycles*, **14** (3), 795-825.

Laurance WF, Laurance SG, Ferreira LV, Ramkin-de Merona J, Gascon C, Lovejoy TE (1997). Biomass collapse in Amazonian forest fragments. *Science* **278** (5340), 1117-1118.

Laurance WF *et al.* (2001) The future of the Brazilian Amazon. *Science*, **292**, 1651-1654.

Malhi, YJ, Roberts T, Betts RA, Killeen TJ, Li W, Nobre CA (2008) Climate change, deforestation and the fate of the Amazon. *Science*, **319**, 169-172.

Marengo JA, Nobre C, Tomasella J, Oyama M, Sampaio G, Camargo H, Alves LM (2008) The drought of Amazônia in 2005. *Journal of Climate*, **21**, 495-516.

Meggers BJ (1994) Archeological evidence for the impact of Mega-Niño events on Amazonia during the past two millennia. *Climate Change*, **28**, 321–338.

Mendonça MJC de, Diaz M del CV, Daniel DC, Seroa R, Alencar A, Gomes JC, Ortiz RA (2004) The economic cost of the use of fire in the Brazilian Amazon. *Ecological Economics*, **49**, 89-105.

Merry F, Soares Filho BS, Nepstad D, Amacher G, Rodrigues H (2008) A Sustainable Future for the Amazon Timber Industry (in press). *Economic Geography*, EUA, 2008.

- Nepstad DC, Carvalho G, Barros AC *et al.* (2001) Road paving, fire regime feedbacks, and the future of Amazon forests Forest. *Ecology and Management*, **154**, 395-407
- Nepstad DC, Lefebvre P, UL Silva *et al* (2004) Amazon drought and its implications for Forest flammability and tree growth: a basin wide analysis. *Global Change Biology*, **10**, 1 – 14.
- Nepstad DC, Moreira AG, Alencar A (1999b) *Flames in the Rain Forest: Origins, Impacts and Alternatives to Amazonian Fire*. The Pilot Program to Conserve the Brazilian Rain Forest, Brasilia, Brazil.
- Nepstad DC, Stickler CM, Almeida OT (2006a) Globalization of the Amazon soy and beef industries: opportunities for conservation. *Conservation Biology*, **20**, 1595-1603.
- Nepstad D, Stickler C, Soares Filho BS, Merry F (2008) Interactions among Amazon land use, forests, and climate: prospects for a near-term forest tipping point. *Philosophical Transactions of The Royal Society*, **363** (1498), 1737-1746.
- Nepstad DC, Schwartzman S, Bamberger B *et al* (2006b) Inhibition of Amazon deforestation and fire by parks and indigenous Lands. *Conservation Biology*, **20**, 65-73
- Nepstad DC, Verissimo A, Alencar A *et al.* (1999a) Large-scale impoverishment of Amazonian forests by logging and fire. *Nature*, **398**, 505-508.
- Nobre CA, Sellers PJ, Shukla J (1991) Amazonian deforestation and regional climate change. *Journal of Climate*, **4**, 957-988.
- NWCG – National Wildfire Coordinating Group (2002). Gaining an Understanding of the National Fire Danger Rating System. Available at:  
<<http://www.nwcg.gov/pms/pubs/MasterGaining.pdf>>.
- Oyama MD, Nobre CA (2003) A new climate-vegetation equilibrium state for tropical South America. *Geophysical Research Letters* **30** (23), doi:10.1029/2003GL018600.

Pontius, RGJr, Schneider L (2001). Land-use change model validation by a ROC method for the Ipswich watershed, Massachusetts, USA. *Agriculture, Ecosystems & Environment* **85** (1-3), 239-248.

Ramanathan V, Crutzen PJ, Kiehl JT, Rosenfeld, D (2001) Aerosols, climate and the hydrological cycle. *Science*, **294**, 2119–2124

Ray D, Nepstad D, Moutinho P (2005) Micrometeorological and canopy controls of fire susceptibility in forested Amazon landscape. *Ecological Applications* **15**, 1664–1678.

Rosenfeld D (1999) TRMM observed first direct evidence of smoke from forest fires inhibiting rainfall. *Geophysical Research Letters*, **26**, 3105–3108.

Rothermel RC (1972) *A Mathematical Model for Predicting Fire Spread ion Wildland fuels*. Intermountain Forest and Range Experiment Station. Forest Service. U.S. Department of Agriculture, USDA. Forest service General Technical Report. INT-115.

Sampaio G, Nobre C, Costa MH, Satyamurty P, Soares-Filho BS, Cardoso M (2007). Regional climate change over eastern Amazonia caused by pasture and soybean cropland expansion. *Geophysical Reesearch Lettes* **34** (17), L17709, doi:10.1029/2007GL030612.

Sismanoglu RA, Setzer AW (2005) Risco de fogo da vegetação na América do Sul: comparação de três versões na estiagem de 2004. *Anais XII Simpósio Brasileiro de Sensoriamento Remoto*, 3349-3355. Goiânia, GO.

Slik JW, Verburg RW, Kebler P JA (2002) Effects of fire and selective logging on the tree species composition of lowland dipterocarp forest in East Kalimantan, Indonesia. *Biodiv. Conserv.* **11**, 85–98.

Soares-Filho B, Alencar A, Nepstad D, Cerqueira GC, Vera Diaz M, Rivero S, Solórzano L, Voll E (2004) Simulating the Response of Land-Cover Changes to Road Paving and Governance Along a Major Amazon Highway: The Santarém-Cuiabá Corridor. *Global Change Biology*, **10** (7), 745-764.

Soares Filho BS, Dietzsch L, Moutinho P et al (2008b) Reducing Carbon Emissions from Deforestation: The Role OF ARPA's Protected Areas in the Brazilian Amazon. Instituto de Pesquisa Ambiental da Amazônia, Brasília, Brazil.



Soares-Filho BS, Nepstad DC, Curran LM *et al* (2006) Modelling conservation in the Amazon basin. *Nature*, **440**, (7083), 520-523

Soares-Filho, BS, Rodrigues, HO, Falieri, A, Costa, WL. Dinâmica EGO Tutorial. 2008  
<<http://www.csr.ufmg.br/dinamica>>

Venevsky S, Thonicke K, Sitch S, Cramer W (2002) Simulating fire regimes in human-dominated ecosystems: Iberian Peninsula case study. *Global Change Biology*, **8**, 984-998.

**MODELO PROBABILÍSTICO DE PROPAGAÇÃO DE FOGO: APLICAÇÃO PARA  
A REGIÃO DO XINGU**

Rafaella Almeida Silvestrini <sup>1</sup>  
Britaldo Silveira Soares Filho <sup>1</sup>  
Ane Auxiliadora Costa Alencar <sup>2</sup>  
Hermann Rodrigues de Oliveira <sup>1</sup>  
Renato Martins Assunção <sup>1</sup>  
Elsa Mendoza <sup>2</sup>

<sup>1</sup> Universidade Federal de Minas Gerais - UFMG  
Av. Antônio Carlos 6627, 31270-901, Belo Horizonte, MG, Brasil

<sup>2</sup> Instituto de Pesquisa Ambiental da Amazônia - IPAM  
Av. Nazaré 669, 66035-170, Belém, Pará, Brasil

Correspondência: Rafaella A. Silvestrini,  
Tel: 55-31-3409-5449, Fax: 55-31-3409-5410  
E-mail: rafaufmg@yahoo.com.br

## ABSTRACT

Fire models developed for the Amazon region rely solely on the occurrence of hot pixels. However, this approach may underestimate fire events, since understory fires are usually not detected by low-resolution thermal imagery. In this work we have developed a spatially explicit simulation model of fire propagation using a cellular automata probabilistic approach implemented on Dinamica EGO platform. This model was developed for the Xingu headwaters in the State of Mato Grosso. The ignitions sources are represented here by hot pixels obtained from NOAA-12 night satellite. The probability for fire to spread is a function of distance to ignition sources, terrain features - such as river channels and topography -, land use, and climatic conditions including Vapor Pressure Deficit and wind prevailing direction. Spatial fitness attained 50% within a window size of 10 km and the fire frequency matched a hundred percent with the observed number of fire events. In a next phase this model will be coupled to a carbon flux model in order to simulate future fire regimes under climate and deforestation scenarios aiming to determine forest resilience thresholds and thereby predict the Amazon ecosystem tipping point.

**Palavras-chave:** understory fires, hot pixels, cellular automata, weights of evidence, Dinâmica EGO, fogo de sub-bosque, focos de calor, autômato celular, pesos de evidência, Dinâmica EGO.

## 1. INTRODUÇÃO

O fogo, principalmente incêndios de sub-bosque, é uma crescente causa de empobrecimento da floresta Amazônica. Estima-se que durante o período El-Niño de 1997-1998, aproximadamente 40.000 km<sup>2</sup> da floresta foram atingidos pelo fogo de sub-bosque, emitindo entre 0,024 a 0,165 Pg de carbono na atmosfera (Alencar et al., 2006), números que tendem a crescer devido ao aumento da frequência de eventos de secas severas no futuro (Cox et al., 2004). Além de alterar a composição da atmosfera, o fogo modifica a estrutura e a diversidade da floresta (Cochrane, 2003), danos que podem ser irreversíveis perante a recorrência do fogo (Nepstad, 2007).

O fogo sempre foi utilizado por moradores locais da Amazônia como uma ferramenta necessária para a manutenção da agricultura e pecuária uma vez que eles conheciam a capacidade da floresta em extingui-lo caso ele escapasse da sua intenção inicial (Nepstad et al., 1999b). Contudo, atualmente, a susceptibilidade da floresta ao fogo tem sido intensificada pela crescente ação do homem (Goldammer et al., 1990), induzindo a fragmentação da floresta e conseqüentemente condições climáticas mais secas, provenientes das áreas desmatadas vizinhas, em seu interior (Kapos et al., 1993; Gascon et al., 2000). Entretanto, a flamabilidade apenas resulta em fogo mediante a presença de uma fonte de ignição, fornecidas em abundância pelas atividades agropecuárias (Alencar et al., 2004).

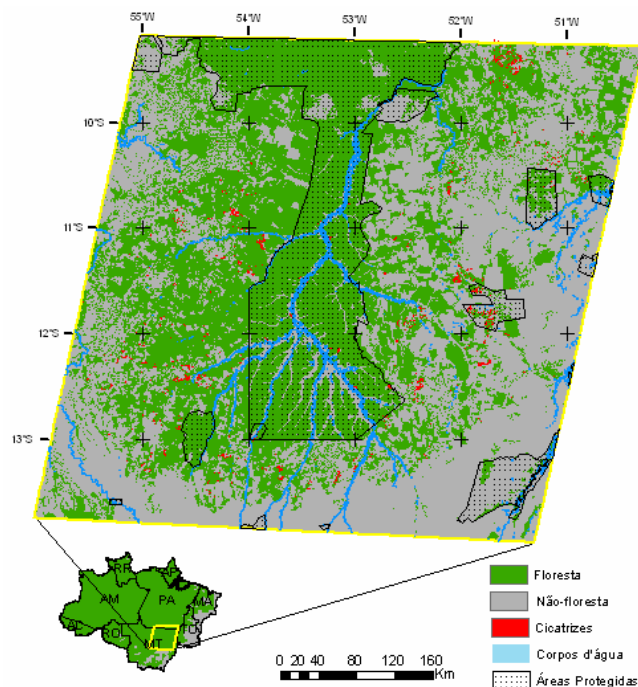
Por comumente se originarem em áreas abertas – como pastagens, áreas de agricultura ou regiões desmatadas – as fontes de ignição dos incêndios de sub-bosque são geralmente captadas pelos satélites de monitoramento, como focos de calor, e disponibilizados gratuitamente na internet (INPE, 2006), ao contrário do fogo que corre abaixo do dossel, dificilmente detectado por estes satélites (Nepstad et al., 1999b). A obtenção de dados de incêndio de sub-bosque fica então condicionada à interpretação de imagens de satélites com melhor resolução espacial, como as LandSat, obtidas logo após o incêndio florestal, haja vista que as cicatrizes de fogo desaparecem das imagens no período de um a dois anos e são frequentemente confundidas com desmatamento (Nepstad et al., 1999a). Portanto, devido à maior dificuldade de se obter dados de incêndio de sub-bosque, os modelos de fogo desenvolvidos para a Amazônia (Cardoso et al., 2003; Nepstad et al., 2004; Sismanoglu e Setzer, 2005; Silvestrini et al., submetido) abordam apenas a ocorrência de focos de calor, como obtido pelos produtos de sensoriamento remoto termal, e não a extensão real das áreas incendiadas.

O modelo apresentado aqui visa simular o processo de propagação do fogo a partir de uma fonte de ignição, em áreas de floresta úmida ou a uma distância máxima de 4 Km destas

áreas, na região do Xingu, norte do Mato Grosso, utilizando-se abordagem probabilística e autômato celular,. A fonte de ignição é dada pela ocorrência de um foco de calor, que pode ser tanto observada como também simulada (Silvestrini et al., submetido). A partir daí o fogo pode-se propagar caso as condições ambientais, climáticas e biofísicas, sejam favoráveis. A calibração do modelo baseou-se em focos de calor do satélite NOAA-12 noite e cicatrizes de incêndios de sub-bosque mapeadas através de imagens LandSat de 2005. Os resultados foram validados comparando-se a área simulada com a observada em termos de extensão e frequência e localização dos eventos de fogo.

## 2. MATERIAIS E MÉTODOS

Modelos de fogo são constituídos basicamente por três componentes: ignição, espalhamento e extinção. Os focos de calor representam os centros de ignição, enquanto a área atingida pelo fogo na floresta se faz representar pelas cicatrizes. O mapeamento destas áreas, bem como da cobertura florestal, se realizou por meio de um índice de fogo que utiliza a diferença normalizada entre o infra-vermelho próximo e termal para mapear as áreas de floresta em pé atingidas por incêndios florestais (Alencar et al., 2006). Essas cicatrizes foram validadas em campo através de entrevistas em julho e agosto de 2007. O mosaico de 9 cenas Landsat obtidas entre 3 de julho a 20 de agosto de 2005 mostram os incêndios ocorridos provavelmente neste ano até o mês de agosto, porém a data exata de cada uma das manchas é desconhecida. A área de estudo, bem como as cicatrizes, pode ser visualizada na Figura 1. A fim de verificar se há dependência espacial entre os focos de calor e as cicatrizes, ou seja, se os focos poderiam dar indicação das fontes de ignição ao processo de espalhamento de fogo, utilizou-se a função K-12 de Ripley (Bailey e Gatrell, 1995), uma técnica estatística que avalia o grau de dependência espacial entre dois tipos de eventos pontuais, e seus envelopes de confiança. Para o cálculo dessa função, as cicatrizes, constituídas de dados de área, foram representadas pelos seus centróides.



**Figura 1:** Área de Estudo e cicatrizes de incêndio de sub-bosque observadas em 2005.

Detectada a dependência espacial positiva entre focos e cicatrizes, o modelo simula, em um passo de tempo mensal e resolução espacial de 320 metros, o espalhamento do fogo a

partir de um foco de calor ocorrido no interior da floresta ou a uma distância máxima de 4 km dela. O fogo é propagado de maneira estocástica para célula vizinha caso a probabilidade de espalhamento seja alta o suficiente. O mapa de probabilidade de espalhamento é uma fusão de dois mapas: um referente à distância custo, que combina variáveis biofísicas para medir o esforço feito pelo fogo em se espalhar, e outro relacionado às condições climáticas no interior da floresta. Quando se inicia o espalhamento, o mapa de probabilidade é ajustado de acordo com a direção do vento e o número de células vizinhas em estado fogo em relação a que está sendo analisada naquele momento pelo autômato celular, implementado sobre a plataforma do Dinamica EGO ([www.csr.ufmg.br/dinamica](http://www.csr.ufmg.br/dinamica)). Cada uma dessas etapas será descrita mais detalhadamente nas subseções seguintes.

## 2.1 Probabilidade referente à distância custo

A probabilidade calculada neste estágio reflete o esforço feito pelo fogo para se propagar a partir de um foco de calor até a célula  $i$ , de maneira que quanto maior o valor de probabilidade maior a facilidade para o fogo atingir a célula. Este mapa de probabilidade tem como variável explicativa a distância custo, a qual integra fatores que podem auxiliar ou desfavorecer o espalhamento, como sentido da encosta, corpos d'água e se a célula está no interior da floresta ou em área desmatada. A distância custo é obtida acumulando os valores de fricção de cada uma das células até o foco de calor mais próximo, sendo o mapa de fricção resultado da aplicação do seguinte algoritmo:

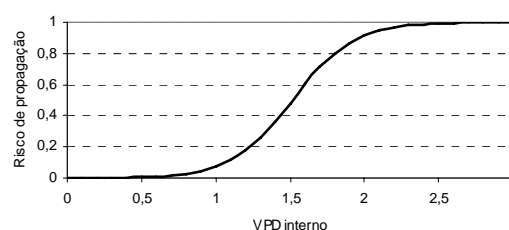
1. Calcula a distância de cada célula até o foco de calor mais próximo;
2. Para cada célula  $i$ :
  - 2.1. Considera janela de vizinhança de 3 x 3 células;
  - 2.2. Escolhe a célula vizinha cuja distância ao foco é a menor. A célula de menor distância é escolhida porque o espalhamento será iniciado a partir de um foco de calor;
  - 2.3. Se a altitude da célula  $i$  é menor que a da célula escolhida em (2.2), então o peso é igual a 2, caso contrário corresponde a 0,5. Desta maneira, o espalhamento é favorecido no sentido morro acima.
  - 2.4. Se a célula  $i$  faz parte da rede hidrográfica, então é somado 0,5 à fricção obtida em (2.3), dificultando o espalhamento perante a existência de água;
  - 2.5. Se a célula  $i$  encontra-se no interior da floresta, acrescenta-se 0,5 ao mapa obtido em (2.4), indicando maior facilidade de propagação fora da floresta, onde as condições climáticas são mais favoráveis.

Nesses cálculos foram considerados os focos de calor de agosto, mês com maior número de focos. Dado o mapa de distância custo, a probabilidade é estimada aplicando-o ao método de pesos de evidência (Bonham-Carter, 1994), escolhido por ser uma técnica de estatística Bayesiana, não paramétrica, portanto mais adequada à modelagem de dados espaciais. Apesar de o modelo apresentar resolução mensal, o mapa de probabilidade dado a distância-custo é calculado anualmente, uma vez que as variáveis envolvidas em seu cálculo não variam significativamente ao longo de um ano. Dados de hidrografia foram fornecidos pela secretaria do Meio Ambiente do Mato Grosso e o mapa de declividade obtido através de imagens SRTM.

## 2.2 Probabilidade relacionada ao clima no interior da floresta

A chance de espalhamento do fogo devido condições climáticas é estimada a partir de uma analogia entre estudos de campo e condições climáticas. Devido à inexistência de dados climáticos no interior da floresta amazônica, foram utilizados valores de déficit de pressão de vapor no interior da floresta, denominado VPD interno, simulados pelo CARLUC – CARbon and Land-Use Change - (Hirsch et al., 2004), modelo que simula o fluxo de carbono entre os componentes da floresta e da floresta para a atmosfera. Ray et al. (2005), analisando florestas no estado do Pará, mostram que o espalhamento do fogo tende a ser inibido quando o VPD interno encontra-se inferior a 0,8; contudo, como a área de estudo do presente trabalho se encontra em uma floresta de transição, com condições climáticas mais secas, espera-se um limiar de VPD interno superior a 0,8. Este limiar foi obtido através da comparação entre os valores de VPD interno das células de cicatrizes com aquelas que não apresentaram fogo, a qual sugeriu que a propagação é favorecida por VPD interno acima de 1,52, pois a maioria das cicatrizes mostrou VPD interno superior a este valor nos meses mais secos (junho a agosto).

A adoção apenas deste limiar na decisão do espalhamento do fogo acarretaria uma função de risco de propagação discreta, enquanto se sabe que quanto mais seco maior a probabilidade de fogo. Por esse motivo optou-se por criar uma função contínua de risco, seguindo uma distribuição logística (Figura 2), estimada através de uma amostra dos valores de VPD interno e das cicatrizes observados. Esta função é aplicada mensalmente nos mapas de VPD interno.



**Figura 2:** Risco de propagação do fogo dado o VPD interno.



### 2.3 Simulação do mecanismo de propagação do fogo

Essa fase utiliza as duas probabilidades descritas anteriormente, juntamente aos dados de campos de vento e o número de vizinhos com fogo à célula sob análise, para simular, estocasticamente em frequência mensal, a propagação do fogo. Os mapas de direção do vento foram fornecidos pelo CPTEC-INPE e constituem-se das médias mensais das componentes zonal e meridional observadas em 2005.


Inicialmente, para cada mês, multiplica-se a probabilidade referente à distância custo pelo risco dado pelo VPD interno, se a célula encontra-se no interior da floresta e caso esteja em área desmatada, considera-se apenas a probabilidade referente à distância custo. A partir deste ponto, tendo como mapa de fogo inicial o mapa de focos de calor, inicia-se a propagação, restrita a 30 repetições, cada uma com os seguintes passos: (1) a probabilidade é multiplicada por um fator de acordo com a direção do vento, que varia de 1,05 se o vento favorece a propagação, a 0,8 caso o vento esteja em sentido contrário ao da propagação em análise naquele instante; (2) a probabilidade é multiplicada por outro fator, que varia de 1, se a célula não possui nenhum vizinho com fogo, a 1,1 se a célula apresenta os 8 vizinhos com fogo. Para evitar que as probabilidades ajustadas por esses fatores ultrapassem 1 ao longo das repetições, trunca-se esta probabilidade em 0,99; (3) verifica-se se o fogo irá se espalhar ou não para a célula vizinha através do sorteio: se o valor da probabilidade é superior a um número aleatório proveniente da distribuição Beta(3;0,9), uma distribuição caudal esquerda, então o fogo passa para a célula vizinha, caso contrário o espalhamento não ocorre. Escolheu-se esta distribuição devido ao histograma dos valores de probabilidade inicial (sem ajuste do vento e da vizinhança) das células em que foi observado fogo de sub-bosque ter apresentado distribuição semelhante à Beta(3;0,9).

A calibração foi feita de maneira que a soma das cicatrizes simuladas mensalmente passe a corresponder, tanto em relação à distribuição espacial quanto em termo de quantidade de células, às cicatrizes observadas. O número de repetições, 30, – superior a 23, número necessário para chegar-se a convergência das áreas queimadas no mês com maior número de focos de calor – foi adotado de maneira a permitir que o fogo se extinga por si mesmo, quando a probabilidade de espalhamento torna-se baixa o suficiente para ser rejeitada pelo teste aleatório.

Depois de efetuada a calibração, o modelo de espalhamento é acoplado ao modelo de ignição (Silvestrini et al., submetido), ou aos focos de calor observados. Os resultados discutidos a seguir utilizam os focos de calor simulados.

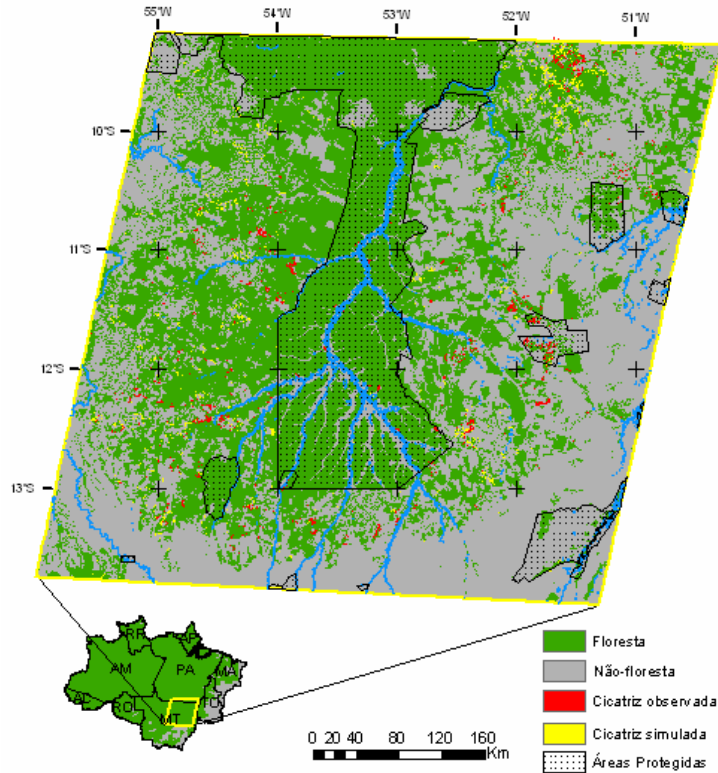
### 3. RESULTADOS E DISCUSSÃO

Considerando a distância-custo, a probabilidade de espalhamento (Figura 3) é superior nas bordas e diminui à medida que se adentra a floresta, em conformidade com estudos anteriores, que relacionam fogo de sub-bosque e características da paisagem (Cochrane e Laurance, 2002; Alencar et al., 2004).



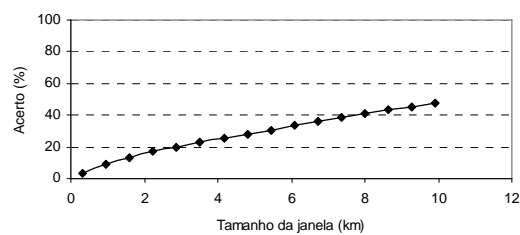
**Figura 3:** Probabilidade de espalhamento devido ao custo acumulado.

A probabilidade climática é integrada ao mapa de probabilidade do custo acumulado mensalmente, e a partir deste ponto os mapas de probabilidade se alteram em função de fatores relacionados à direção do vento e ao número de células vizinhas em estado fogo. O resultado da aplicação desses mapas dinâmicos no autômato celular é apresentado na Figura 4, a qual mostra a fusão das manchas de espalhamento obtidas em cada um dos meses. A quantidade de células de cicatrizes simuladas é 1% maior que a quantidade das manchas observadas. A distribuição temporal da quantidade de cicatrizes de sub-bosque simuladas mensalmente seguiu o padrão esperado para a região: aumento da área queimada nos meses mais secos, entre maio e agosto. Este resultado deve-se não apenas à pequena quantidade de focos de calor simulados no início do ano, mas também ao efeito da probabilidade de espalhamento nestes meses, pois se observou que os poucos focos ocorridos não se propagaram devido à baixa probabilidade de espalhamento, condicionada principalmente pelo clima, mais úmido nos primeiros meses do ano.



**Figura 4:** Áreas atingidas pelo fogo simuladas e observadas

A Figura 4 mostra que as áreas simuladas e observadas tendem a se concentrar nas mesmas regiões, próximas às áreas desmatadas. A concordância espacial entre cicatrizes simuladas e observadas foi testada através do método Fuzzy (Soares-Filho et al., 2008), que calcula a porcentagem de acerto considerando diferentes tamanhos de janela. No gráfico da Figura 5, é mostrado que em uma janela de aproximadamente 10 x 10 km, 50% das células simuladas coincidem com as observadas.



**Figura 5:** Similaridade entre cicatrizes observadas e simuladas.

Em próximas versões, seria desejável a obtenção de dados de incêndio de sub-bosque com resolução temporal mensal, pois permitiria calibração e validação dos resultados mais refinada. Melhorias adicionais seriam observadas também ao incorporar o efeito do fogo na quantidade de combustível e no clima local, fatores que levam a modificações na intensidade e no intervalo de recorrência do fogo (Balch et al., 2008). A incorporação destes fatores será

realizada na próxima versão através do acoplamento do modelo de fogo ao CARLUC (Hirsch et al., 2004), o qual modifica as condições climáticas e a quantidade e alocação da biomassa após a ocorrência do fogo, exploração madeireira seletiva e desmatamento.

#### **4. CONCLUSÕES**

Este artigo apresenta a primeira versão da metodologia do espalhamento de fogo, parte integrante de um modelo pioneiro na Amazônia ao considerar todas as fases de um incêndio: ignição, propagação e extinção.

O modelo de espalhamento, juntamente às fontes de ignição previamente simuladas, mostrou que a abordagem probabilística adotada neste trabalho – através das variáveis distância a uma fonte de ignição, declividade, condições climáticas no interior da floresta, presença de corpos d'água e floresta densa – é capaz de fornecer estimativas satisfatórias da quantidade e localização da área queimada, apesar da necessidade de incorporar o efeito do fogo na probabilidade no espaço de tempo seguinte. A área atingida pelo fogo foi 1% superior que a observada e considerando a distribuição espacial das manchas, observou-se 50% de acerto em uma janela de 10 x 10 km.

Simulações de cenários futuros para a Amazônia (Soares-Filho et al., 2006) não consideram o fogo como um dos distúrbios responsáveis pela degradação da floresta devido à inexistência de modelos de fogo. Futuramente, a integração do modelo apresentado neste trabalho ao CARLUC permitirá a simulação de cenários futuros para a região do Xingu, incluindo as perturbações pelo fogo em conjunto com desmatamento e exploração madeireira.

#### **AGRADECIMENTOS**

Somos gratos ao Instituto de Pesquisa Ambiental da Amazônia (IPAM), projeto Large-Scale Biosphere Atmosphere Experiment (LBA-ECO) e ao CNPq pelo financiamento desta pesquisa. Agradecemos também ao Dr. Saulo Freitas, que forneceu os dados de campos de vento, e Daniel Nepstad pelo incentivo.

## REFERÊNCIAS BIBLIOGRÁFICAS

Alencar, A.; Nepstad, D.C.; Diaz, M.C.V. Forest understory fire in the Brazilian Amazon in ENSO and non- ENSO years: Area burned and committed carbon emissions. **Earth Interactions**, v. 10, n. 6, p. 1-16, 2006.

Alencar A.; Solorzano, L.A., Nepstad, D.C. Modeling forest understory fires in an eastern Amazonian landscape. **Ecological Applications**, v. 14, n. 4, p. S139–S149, 2004.

Bailey, T.; Gatrell, A. **Interactive Spatial Data Analysis**, Harlow: Longman, 1995, 413 p.

Balch, J.K.; Nepstad, D.C.; Brando, P.M.; Curran, L.C.; Portela, O.; de Carvalho Jr, O.; e Lefebvre, P. Negative fire feedback in a transitional forest of Southeastern Amazonia. **Global Change Biology**, v. 14, p. 1-12, 2008.

Bonham-Carter, G 1994. **Geographic information systems for geoscientists: modelling with GIS**. New York, Pergamon, 398 p.

Cardoso, M.F.; Hurtt C.G.; Moore, B.; Nobre, C.A.; Prins, E.M. Projecting future fire activity in Amazonia. **Global Change Biology**, v. 9, p. 656 – 669, 2003.

Cochrane, M.A. Fire Science for rainforests. **Nature**, v. 421, p. 913-919, 2003.

Cochrane, M.A.; Laurance, W.F. Fire as a large scale edge effect in Amazonian forests. **Journal of Tropical Ecology**, v. 18, p. 311–325, 2002.

Cochrane, M.A. Synergistic interactions between habitat fragmentation and fire in evergreen tropical forests. **Conservation Biology**, v. 15, n. 6, p. 1515–1521, 2001.

Cox, P.M.; Betts, R.A.; Collins, M.; Harris, P.P.; Huntingford, C.; Jones, C.D.; Amazonian forest dieback under climate-carbon cycle projections for the 21st century. **Theoretical and Applied Climatology**, v. 78, p. 137-156, 2004.

Goldammer, J. G. Fire in the Tropical Biota. Berlin: Springer, 1990.

Hirsch, A.I.; Little, W.S.; Houghton, R. A.; Scott, N.A.; White, J. D. The net carbon flux due to deforestation and forest re-growth in the Brazilian Amazon: analysis using a process-based model. **Global Change Biology**, v. 10, p. 908 – 924, 2004.

Inpe. Instituto Nacional de Pesquisas Espaciais. Monitoramento de queimadas. Disponível em <<http://www.cptec.inpe.br/queimadas>> Acesso em 22 Novembro.2006.

Kapos, V.; Ganade, G.; Matsui, E.; Victoria, R.L..  $\delta^{13}C$  as an indicator of edge effects in tropical rainforest reserves. *Journal of Ecology*, v. 81, p. 425-432, 1993

Nepstad, D. The Amazon's Vicious Cycles. Drought and fire in the greenhouse. Ecological and climatic tipping points of the world's largest tropical rainforest and practical preventative measures. World Wildlife Fund. In: United Nations Framework Convention on Climate Change (UNFCCC) Conference of the Parties (COP), Dezembro, 2007, Bali, Indonesia.

Disponível em:

<[http://www.whrc.org/resources/published\\_literature/pdf/NepstadWWF.07.pdf](http://www.whrc.org/resources/published_literature/pdf/NepstadWWF.07.pdf)>. Acesso em 20 jun. 2008.

Nepstad, D.C.; Lefebvre, P.; Silva, U.L.; Tomasella, J.; Schlesinger, P.; Solórzano, L.; Moutinho, P.; Ray, D.; e Guerreira Benito, J. Amazon drought and its implications for Forest flammability and tree growth: a basin wide analysis. **Global Change Biology**, v. 10, p. 1–14, 2004.

Nepstad, D.C.; Veríssimo, A.; Alencar, A.; Nobre, C.; Lima, E.; Lefebvre, P.; Schlesinger, P.; Potter, C.; Moutinho, P.; Mendoza, E.; Cochrane, M.; e Brooks, V. Large-scale impoverishment of Amazonian forests by logging and fire. **Nature**, v. 398, p. 505-508, 1999a.

Nepstad, D. C.; Moreira, A. G.; Alencar, A. Flames in the rain forest: Origins, impacts and alternatives to Amazonian Fire. Brasília: Editora Universidade de Brasília, 1999b. 140 p.

Ray, D.; Nepstad D. C.; Moutinho, P. Micrometeorological and Canopy Controls of fire susceptibility in an East-Central Amazon Landscape. *Ecological Applications*, v. 15, n. 5, p. 1664-1678, 2005.

Silvestrini, R.A, Soares-Filho, B.S., Oliveira, H.O., Assunção, R.M., Nepstad, D.C. (2009, submetido). Simulating the occurrence of hot pixels in the Amazon Forest. **Global Change Biology**.

Sismanoglu R.A., Setzer A.W. Risco de fogo da vegetação na América do Sul: comparação de três versões na estiagem de 2004. In: Simpósio Brasileiro de Sensoriamento Remoto (SBSR), 12., 2005, Goiânia. **Anais...** São José dos Campos: INPE, 2005. Artigos, p. 3349-3355. CD-ROM, On-line. ISBN 85-17-00018-8. Disponível em: <<http://marte.dpi.inpe.br/col/ltid.inpe.br/sbsr/2004/11.22.09.33/doc/3349.pdf>> Acesso em: 20 out. 2007.

Soares-Filho, B.S., Rodrigues, H.O., Falieri, A., Costa, W.L. Dinâmica EGO Tutorial. 2008 <<http://www.csr.ufmg.br/dinamica>>

Soares-Filho, B.S.; Nepstad, D.C.; Curran, L.M.; Cerqueira1, G.C.; Garcia, R.A.; Ramos, C.A.; Voll, E.; McDonald, A.; Lefebvre, P.; e Schlesinger. P. Modelling conservation in the Amazon basin. **Nature**, v. 440, n. 7083, p.520-523, 2006.



## CONSIDERAÇÕES FINAIS

Neste estudo foram abordadas todas as fases da modelagem de fogo: ignição, propagação e extinção. As fontes de ignição foram avaliadas pelo modelo de focos de calor, desenvolvido para a Amazônia Brasileira em resolução de 2 x 2 km, enquanto a propagação e a extinção foram analisadas através do modelo de espalhamento, com resolução de 320 m, na região do Xingu, norte do estado do Mato Grosso.

Foi evidenciado que variáveis relacionadas à interferência humana - como distancia aos centros de municípios, estradas e áreas protegidas - têm um papel muito importante na modelagem de fogo na Amazônia, onde fogo não é apenas um desastre natural, na maioria das vezes ele está relacionado à prática do uso da terra. Apesar da resolução fina, 2 x 2 km, o que torna mais difícil a concordância entre observado e simulado, a validação do modelo de focos de calor, que integra variáveis climáticas e biofísicas, produziu bons resultados tanto em relação à quantidade quanto à distribuição espacial dos focos simulados. O mapa de probabilidade também produziu resultados bastante satisfatórios, uma vez que a estatística ROC foi superior a 0,85 em todos os meses analisados, entre 2002 e 2005, mostrando que ele pode ser utilizado no monitoramento do fogo nas regiões de floresta da Amazônia.

Além de obter a extensão de possíveis áreas a serem queimadas, a modelagem do espalhamento de fogo é importante para que a partir dos focos de calor diariamente monitorados, seja possível ficar atento as regiões mais propensas ao espalhamento do fogo, principalmente aqueles de sub-bosque, que dificilmente são detectados por satélites. Esta etapa da modelagem também produziu bons resultados, pois a porcentagem de acerto em uma janela de 22 x 22 km foi de 50% e a distribuição sazonal da ocorrência de fogo, aumento da frequência em épocas secas, período de junho a setembro, foi respeitada pelo modelo.

O crescente aumento da frequência do fogo em áreas de floresta da Amazônia mostra a necessidade de se realizar estudos com a finalidade de compreender melhor a dinâmica do fogo e estabelecer os limiares de clima e combustível a partir dos quais o espalhamento do fogo é desfavorecido. A realização destes estudos tornaria a modelagem de fogo na Amazônia mais bem elaborada e, juntamente a cenários climáticos e a modelos de combustíveis, permitiria a simulação de regimes de fogo no futuro.