

CENTRO UNIVERSITÁRIO DE ANÁPOLIS - UniEVANGÉLICA
MESTRADO EM SOCIEDADE, TECNOLOGIA E MEIO AMBIENTE

EUDE DE SOUSA CAMPOS

DETECÇÃO DE MUDANÇAS TEMPORAIS APLICADAS NA ANÁLISE DA
PRODUÇÃO BIOENERGÉTICA E PECUÁRIA EM GOIÁS EM 1995 E 2010

ANÁPOLIS-GO

2013

EUDE DE SOUSA CAMPOS

DETECÇÃO DE MUDANÇAS TEMPORAIS APLICADAS NA ANÁLISE DA
PRODUÇÃO BIOENERGÉTICA E PECUÁRIA EM GOIÁS EM 1995 E 2010

Dissertação apresentada ao Programa de Pós-Graduação stricto sensu - Mestrado em Sociedade, Tecnologia e Meio Ambiente do Centro Universitário de Anápolis - UniEVANGÉLICA, como requisito final para obtenção do título de Mestre.

Área de concentração: Tecnologia e Meio Ambiente.

Orientador: Prof. Dr. Nilton Correia da Silva.

ANÁPOLIS-GO

2013

C198

Campos, Eude de Sousa.

Detecção de mudanças temporais aplicadas na análise da produção bioenergética e pecuária em Goiás em 1995 e 2010 / Eude de Sousa Campos. – Anápolis: Centro Universitário de Anápolis – UniEvangélica, 2013.

170 p. il.

Orientador: Prof. Dr. Nilton Correia da Silva.

Dissertação (mestrado) – Programa de Pós-Graduação em Sociedade, Tecnologia e Meio Ambiente – Centro Universitário de Anápolis – UniEvangélica, 2013.

1. Mudanças temporais 2. Produção bioenergética 3. Produção pecuária
4. Goiás (1995/2010) I. Silva, Nilton Correia da. II. Título.

CDU 504

EUDE DE SOUSA CAMPOS

Dissertação de Mestrado intitulada “Detecção de Mudanças Temporais aplicadas na análise da Produção Bioenergética e Pecuária em Goiás em 1995 e 2010”, apresentada ao Centro Universitário de Anápolis – UniEVANGÉLICA, como requisito para a obtenção do Título de Mestre em Sociedade, Tecnologia e Meio Ambiente.

Defendida em Anápolis, 20 de dezembro de 2013.

BANCA EXAMINADORA:

Prof. Dr. Nilton Correia da Silva
Centro Universitário de Anápolis – UniEVANGÉLICA
Orientador

Prof. Dr. Osmar Abílio de Carvalho Júnior
Universidade de Brasília – UnB
Professor Convidado

Prof. Dr. Clarimar José Coelho
Centro Universitário de Anápolis – UniEVANGÉLICA
Professor Convidado

DEDICATÓRIA

Aos meus pais, em especial a minha mãe **Celina**, que sempre foram fonte de incentivo e apoio à minha qualificação; aos meus queridos amigos **Mara, Gislene e Wilson** pela força e apoio constante; a todos os colegas que sempre foram incentivadores nas horas mais difíceis.

AGRADECIMENTOS

A **Deus** pelas bênçãos em minha vida.

Em especial ao meu orientador, Professor **Dr. Nilton Correia da Silva**, pela confiança, o tempo gasto e as importantes orientações. Obrigado por acreditar na pesquisa e em minha capacidade. Durante os dias de orientações, aprendi a ser paciente, ter concentração e capaz de romper paradigmas antes verdades absolutas. Aprendi que o mestre deve ter humildade para poder assimilar novos conhecimentos continuamente.

A todos os **Professores** do programa do Mestrado em Sociedade, Tecnologia e Meio Ambiente, pelo apoio e os novos conhecimentos apreendidos.

Um abraço especial ao Professor **Dr. Roberto Prado** (*In Memoriam*), por suas aulas de qualidade, pelo auxílio durante a minha pesquisa e também por ensinar-me que é possível ser Doutor com humildade e humanidade.

A todos os **colegas da turma** pelos bons momentos vividos e pelo conforto nas horas de desespero e desânimo.

Aos meus grandes amigos: **Mara Rúbia, Wilson Clério e Gislene Lisboa** por todo o incentivo e apoio em horas difíceis. Um abraço!

A todos os **servidores** do Programa de mestrado em Sociedade, Tecnologia e Meio Ambiente da UniEVANGÉLICA, em especial a **Eunice** por toda a paciência e boa vontade.

Ao meu amigo **Igor**, grato pelas horas despendidas para auxiliar-me com a escrita da dissertação! Obrigado!

Ao meu amigo **Kauê**, grato pela paciência e o bom humor de todas as horas e pela companhia. Um Abraço!

Aos meus **familiares**, em especial minha **Mãe (Celina)**, que sempre acreditaram na realização desse trabalho.

A colega **Natasha Sophie** pela grande ajuda durante a fase de testes laboratoriais, o que permitiu a conclusão da pesquisa. Também ao amigo **Caio Nunes** pela paciência e ajuda com o software MatLab.

E a todos os **colegas** que contribuíram de alguma maneira para a realização do trabalho.

*“Matar o sonho é matarmo-nos. É mutilar a
nossa alma. O sonho é o que temos de realmente
nosso, de impenetravelmente e
inexpugnavelmente nosso.”*

Fernando Pessoa

RESUMO

Dados oficiais relativos ao setor bioenergético e da pecuária bovina de corte e leiteira em Goiás foram utilizados na aplicação de detecção de mudança com ênfase aos sistemas auto-organizáveis (mapas de Kohonen) como método não supervisionado de classificação para verificar o comportamento produtivo relacionado à cultura da cana-de-açúcar e da pecuária (carne e leite) nos municípios goianos. A pesquisa adotou dois tempos (bitemporal) específicos de análise em uma dimensão de sinclassificação (classificação simultânea). As análises realizadas permitiram monitorar temporalmente as modificações relativas ao comportamento da produtividade nos municípios goianos. Todas as ferramentas tecnológicas disponíveis na atualidade podem e devem ser utilizadas na análise de dados de produção de modo que variáveis numéricas quantificadas por Institutos Especializados possam ser transformadas em informações úteis ao planejamento e gestão quer seja, rural ou urbana, em esferas municipais, estaduais e federais. Em uma análise bitemporal são escolhidos dois tempos específicos para o estudo e o algoritmo de classificação determinará padrões para a definição dos grupos a serem classificados. Em uma abordagem de sinclassificação, o treinamento é realizado de forma que os dados dos dois tempos sejam tabulados de forma simultânea. Ao final, busca-se determinar ou não a ocorrência de mudanças ou modificações temporais.

Palavras-chave: Detecção de mudança temporal. Sinclassificação. Sistemas auto-organizáveis. Tecnologias.

ABSTRACT

Official data on bioenergy sector and beef cattle and dairy Goiás were used in the application of change detection systems with emphasis on self-organizing (Kohonen maps) as unsupervised method of classification to verify the productive behavior related to culture of cane sugar and livestock (meat and milk) in the municipalities of Goiás. The research adopted two times (bitemporal) analysis on a specific dimension sinclassificação (simultaneous classification). The analyzes allowed temporally monitor the changes relating to the behavior of productivity in municipalities in Goiás. All the technological tools available today can and should be used in the analysis of production data so that numerical variables quantified by specialized institutes can be turned into useful information for planning and management whether rural or urban, in municipal, state and federal. In an analysis bitemporal are chosen two specific times for the study and classification algorithm determines standards for the definition of groups to be classified. In one approach sinclassificação. The training is conducted so that the data of the two times are plotted simultaneously. At the end, we seek to determine whether or not the occurrence of temporal changes or modifications.

Keywords: Detecting temporal change. Sinclassification. Self-organizing systems. Technologies.

LISTA DE FIGURAS

Figura 1 – Mudança temporal utilizando sinclassificação	35
Figura 2 – Estrutura de um neurônio humano	38
Figura 3 – Esquema da unidade de McCulloch e Pitts	42
Figura 4 – Topologia de uma RNA : Multi Layer Perception	43
Figura 5 – Estrutura de uma RNA de Kohonen	46
Figura 6 – Localização Geográfica do Estado de Goiás	47
Figura 7 – Estado de Goiás e regiões de planejamento	49
Figura 8 – DMB - SOFM: RNA utilizada no processo de detecção de mudanças referente às variações produtivas utilizadas na pesquisa	59
Figura 9 – Exemplo da topologia de uma rede de Kohonen	60
Figura 10 – Saída dos elementos da vizinhança do neurônio vencedor, para efeito de ajustados pesos sinápticos	62
Figura 11 – Interface do MATLAB 7.10.0	66
Figura 12 – Agrupamento de um conjunto de dados (a) dados originais; (b) divisão em dois grupos; (c) divisão em quatro grupos. Cada grupo está indicado por uma cor diferente.....	68
Figura 13 – Cálculo da distância Euclidiana	70
Figura 14 – Interface do ArcGis 10.1 (ArcMap)	71
Figura 15 – Representação do ECA e SIG	74
Figura 16 – Comportamento relativo à área plantada de cana-de-açúcar. À esquerda Rede SOFM 15 x 15 (classificação relativa a produtividade); a direita Distribuição por Grupo (Quantitativo de municípios agrupados)	85
Figura 17 – Comportamento relativo à pecuária de corte em nº de cabeças. À esquerda Rede SOFM 15 x 15 (classificação relativa a produtividade); a direita Distribuição por Grupo (Quantitativo de municípios agrupados)	86
Figura 18 – Comportamento relativo à produção leiteira em litros. À esquerda Rede SOFM 15 x 15 (classificação relativa a produtividade); a direita Distribuição por Grupo (Quantitativo de municípios agrupados)	86
Figura 19 – Comportamento relativo à área plantada de cana-de-açúcar	92

Figura 20 – Legenda de cor relacionada ao mapa de classificação temporal	93
Figura 21 – Classificação da área plantada de cana-de-açúcar no Estado de Goiás, com a utilização de rede neural artificial de Kohonen com dimensão 5 x 5. (a) Ano de 1995 (b) Ano de 2010	94
Figura 22 – Legenda correspondente aos mapas de mudança e não mudança	95
Figura 23 – Detecção de mudanças da área plantada de cana-de-açúcar no Estado de Goiás, com a utilização de rede neural artificial de Kohonen com dimensão 5 x 5 (a) Mapa de Mudança (b) Mapa de Não Mudança	96
Figura 24 – Comportamento relativo ao rebanho bovino de corte	100
Figura 25 – Legenda de cor relacionada ao mapa de classificação temporal	101
Figura 26 – Classificação do rebanho de corte no Estado de Goiás, com a utilização de rede neural artificial de Kohonen com dimensão 5 x 5. (a) Ano de 1995 (b) Ano de 2010.....	102
Figura 27 – Legenda correspondente aos mapas de mudança e não mudança	103
Figura 28 – Detecção de mudanças do rebanho de corte no Estado de Goiás, com a utilização de rede neural artificial de Kohonen com dimensão 5 x 5(a) Mapa de Mudança (b) Mapa de Não Mudança	104
Figura 29 – Comportamento relativo a produção leiteira	110
Figura 30 – Legenda de cor relacionada ao mapa de classificação temporal	111
Figura 31 – Classificação da produção leiteira no Estado de Goiás, com a utilização de rede neural artificial de Kohonen com dimensão 5 x 5 (a) Ano de 1995 (b) Ano de 2010.....	112
Figura 32 – Legenda correspondente aos mapas de mudança e não mudança	113
Figura 33 – Detecção de mudanças da produção leiteira no Estado de Goiás, com a utilização de rede neural artificial de Kohonen com dimensão 5 x 5 (a) Mapa de Mudança. (b) Mapa de Não Mudança	114
Figura 34 – A esquerda Rede SOFM 5 x 5 (classificação relativa a produtividade); a direita Distribuição por Grupo (Quantitativo de municípios classificados)	153
Figura 35 – A esquerda Rede SOFM 7 x 7 (classificação relativa a produtividade); a direita Distribuição por Grupo (Quantitativo de municípios classificados)	154
Figura 36 – A esquerda Rede SOFM 9 x 9 (classificação relativa a produtividade); a direita Distribuição por Grupo (Quantitativo de municípios classificados)	155
Figura 37 – A esquerda Rede SOFM 13 x 13 (classificação relativa a produtividade); a direita	

Distribuição por Grupo (Quantitativo de municípios classificados)	156
Figura 38 – A esquerda Rede SOFM 17 x 17 (classificação relativa a produtividade); a direita Distribuição por Grupo (Quantitativo de municípios classificados)	157
Figura 39 – A esquerda Rede SOFM 19 x 19 (classificação relativa a produtividade); a direita Distribuição por Grupo (Quantitativo de municípios classificados)	158
Figura 40 – A esquerda Rede SOFM 5 x 5 (classificação relativa a produtividade); a direita Distribuição por Grupo (Quantitativo de municípios classificados)	159
Figura 41 – A esquerda Rede SOFM 7 x 7 (classificação relativa a produtividade); a direita Distribuição por Grupo (Quantitativo de municípios classificados)	160
Figura 42 – A esquerda Rede SOFM 9 x 9 (classificação relativa a produtividade); a direita Distribuição por Grupo (Quantitativo de municípios classificados)	161
Figura 43 – A esquerda Rede SOFM 13 x 13 (classificação relativa a produtividade); direita Distribuição por Grupo (Quantitativo de municípios classificados)	162
Figura 44 – A esquerda Rede SOFM 17 x 17 (classificação relativa a produtividade); a direita Distribuição por Grupo (Quantitativo de municípios classificados)	163
Figura 45 – A esquerda Rede SOFM 19 x 19 (classificação relativa a produtividade); a direita Distribuição por Grupo (Quantitativo de municípios classificados)	164
Figura 46 – A esquerda Rede SOFM 5 x 5 (classificação relativa a produtividade); a direita Distribuição por Grupo (Quantitativo de municípios classificados)	165
Figura 47 – A esquerda Rede SOFM 7 x 7 (classificação relativa a produtividade); a direita Distribuição por Grupo (Quantitativo de municípios classificados)	166
Figura 48 – A esquerda Rede SOFM 9 x 9 (classificação relativa a produtividade); a direita Distribuição por Grupo (Quantitativo de municípios classificados)	167
Figura 49 – A esquerda Rede SOFM 13 x 13 (classificação relativa a produtividade); a direita Distribuição por Grupo (Quantitativo de municípios classificados)	168
Figura 50 – A esquerda Rede SOFM 17 x 17 (classificação relativa a produtividade); a direita Distribuição por Grupo (Quantitativo de municípios classificados)	169
Figura 51 – A esquerda Rede SOFM 19 x 19 (classificação relativa a produtividade); a direita Distribuição por Grupo (Quantitativo de municípios classificados)	170

LISTA DE GRÁFICOS

Gráfico 1 – Frequência de distribuição da produção de cana-de-açúcar em hectares	57
Gráfico 2 – Diferentes dimensões de redes e a distribuição estatística dos dados (produção de cana em ha)	84

LISTA DE QUADROS

Quadro 1 – Regiões de planejamento de Goiás e o quantitativo de municípios	49
Quadro 2 – Usinas produtoras de álcool e açúcar nos 5 maiores estados produtores	51
Quadro 3 – Municípios Goianos com alta produção de cana-de-açúcar (área plantada em hectares)	53
Quadro 4 – Municípios Goianos com alta produção do rebanho bovino de corte/ano 2010 (número de cabeças)	54
Quadro 5 – Municípios Goianos com alta produção do rebanho bovino de leite/ano 2010 (mil litros)	56
Quadro 6 – Consumo de milho e soja em 20 cidades	74
Quadro 7 – Definição do range de classificação e centróides	74
Quadro 8 – Resultados da classificação temporal (área plantada de cana-de-açúcar (em há)).....	81
Quadro 9 – Resultados da classificação temporal (pecuária bovina de corte (nº de cabeças)).....	82
Quadro 10 – Resultados da classificação temporal (pecuária bovina leiteira (em litros)).....	82
Quadro 11 – Relação grupo, centróide e quantitativo de municípios classificados em 1995 e 2010	91
Quadro 12 – Análise de mudança da produção para os municípios goianos	97
Quadro 13 – Relação grupo, centróide e quantitativo de municípios classificados em 1995 e 2010	99
Quadro 14 – Análise de mudança da produção para os municípios goianos	105
Quadro 15 – Relação grupo, centróide e quantitativo de municípios classificados em 1995 e 2010	109
Quadro 16 – Análise de mudança da produção para os municípios goianos	115

LISTA DE TABELAS

Tabela 1 – Parâmetros de treinamento da rede SOFM	76
Tabela 2 – Configurações de treinamento: cana-de-açúcar	78
Tabela 3 – Configurações de treinamento: rebanho bovino de corte	79
Tabela 4 – Configurações de treinamento: rebanho bovino de leite	80

LISTA DE ABREVIATURAS E SIGLAS

I(SIG)	Índice de Similaridade Intra Grupo
SIG	Similaridade Intra Grupo
C	Change (Mudança)
CC	Cana fase Convergência
CO	Cana fase Ordenação
CONAB	Companhia Nacional de Abastecimento
DM	Detecção de Mudanças
DMB	Detecção de Mudança Bitemporal
ECA	Erro de Classificação da Amostra
EMBRAPA	Empresa Brasileira de Pesquisa Agropecuária
FCO	Fundo Constitucional do Centro-Oeste
GSDIS-GO	Gerência de Sistematização e Disseminação de Informações Socioeconômicas
IBGE	Instituto Brasileiro de Geografia e Estatística
IMB-GO	Instituto Mauro Borges de Goiás
INPE	Instituto Nacional de Pesquisas Espaciais
LC	Leite fase Convergência
LO	Leite fase Ordenação
MATLAB	MATrix LABoratory
MLP	Multi Layer Perceptron
MMA	Ministério do Meio Ambiente
NC	No Change (Não Mudança)
Nor	normalização
PIB	Produto Interno Bruto
PROÁLCOOL	Programa Nacional do Álcool
RC	Rebanho fase Convergência
RNA	Rede Neural Artificial
RO	Rebanho fase Ordenação
SEPIN-GO	Superintendência de Estatística Pesquisa e Informação de Goiás
SEPLAN-GO	Secretaria de Planejamento de Goiás
SIDRA	Sistema IBGE de Recuperação Automática
SIG	Sistema de Informação Geográfica
SOFM	<i>Self Organizing Feature Maps</i>
SOM	<i>Self-Organizing Map</i>
SUDAM	Superintendência de Desenvolvimento da Amazônia
SUDECO	Superintendência de Desenvolvimento do Centro Oeste
TI	Tecnologias da Informação
ÚNICA	União da Indústria de Cana-de-Açúcar

LISTA DE SÍMBOLOS

T	Quantidade de intervalos de tempos
t_1	Tempo 1
$>$	Maior
$<$	Menor
\sum	Somatório
ϵ	Pertence
x_n	Quantidade de amostras
n	número de classes
x_i	elemento de um vetor
w_{ij}	Pesos entre os neurônios i e j
y	Saída da RNA
x, X_j	vetor de amostra
c	vetor do centroide do grupo de x
D	dimensão dos dados (amostra e centroide);
j	índice de uma amostra.
k	quantidade de amostras classificadas por C_w
w	índice de um grupo
ΔX	$\max\{X\} - \min\{X\}$
x_p	Sinais de entrada
w_p	Pesos dos neurônios
h_{ji}	Excitação de um neurônio j
d_{ji}	Distância entre o neurônio j e o neurônio vencedor i
σ	Largura real da vizinhança topológica entre dois neurônios
$d(x_i, x_w)$	distância Euclidiana
p	valores de entrada
$\max \{ \circ \}$	Valor máximo de um conjunto numérico
$\min \{ \circ \}$	Valor mínimo de um conjunto numérico

SUMÁRIO

1 INTRODUÇÃO	19
1.1 Apresentação do Tema	19
2 APRESENTAÇÃO DO PROBLEMA	25
2.1 A produção sucroalcooleira e a pecuária em Goiás.....	25
2.2 A Geotecnologia e as ferramentas que facilitam a análise de dados de produção	29
2.3 Objetivos.....	31
2.3.1 Geral	31
2.3.2 Específicos.....	32
3 ORIENTAÇÕES CONCEITUAIS	33
3.1 Detecção de mudanças.....	33
3.1.1 Série discreta.....	33
3.1.2 Série contínua	34
3.2 Classificação e mudança temporal	34
3.2.1 Método supervisionado	36
3.2.2 Método não supervisionado	36
3.2.2.1 Redes neurais artificiais (RNA)	37
3.2.2.2 SOFM (Self Organizing Feature Maps): rede de Kohonen	44
4 MATERIAIS E MÉTODOS	47
4.1 Área de estudo	47
4.1.1 A produção sucroalcooleira no Brasil e Goiás	51
4.1.2 Os indicadores de produtividade do Estado de Goiás relacionados ao setor sucroalcooleiro (produção de cana-de-açúcar), pecuária de corte bovina e pecuária leiteira...52	
4.2 Etapas da pesquisa	58
4.3 Descrição e interface dos softwares utilizados	59
4.3.1 SOFM: Detecção de Mudanças (DBF – 2 tempos)	59
4.3.1.1 Parâmetros de Treinamento utilizados na pesquisa	63
4.3.2 Matlab 7.10.0 R2010a (MATrix LABoratory)	66
4.3.2.1 Agrupamento de dados	67
4.3.2.2 Medidas de similaridade	68

4.3.2.3 Similaridade entre dados de um mesmo grupo	69
4.3.3 ArcGis 10.1 (ArcMap).....	71
5 RESULTADOS E DISCUSSÃO	72
5.1 Índice de Análise utilizado na pesquisa.....	72
5.1.1 Similaridade Intra Grupos.	72
5.2 A sinclassificação temporal aplicada à produção de cana-de-açúcar e pecuária bovina de corte e leiteira em Goiás.	75
5.2.1 Experimentos de classificação realizados com a rede SOFM.	78
5.2.1.1 Parâmetros de treinamento da rede SOFM.....	78
5.2.1.2 Resultados obtidos para o processo de classificação temporal.	81
5.2.1.3 Comportamento da Rede SOFM e Distribuição por Grupo.	85
5.2.1.4 Resultados da Sinclassificação.	87
5.3 Aplicabilidade e vantagens da utilização do método de classificação.	88
5.4 A detecção de mudança temporal relacionada à área plantada de cana-de-açúcar, rebanho de corte bovino e produção leiteira dos municípios goianos.	90
5.4.1 A Detecção de Mudanças para a Área Plantada de Cana-de-Açúcar em Goiás	91
5.4.2 A Detecção de Mudanças para a Pecuária Bovina de Corte em Goiás.	99
5.4.3 A Detecção de Mudanças para a Produção Leiteira em Goiás.....	109
6 CONCLUSÕES.....	120
6.1 Trabalhos Futuros.	123
6.2 Publicações do autor relacionadas ao trabalho.	123
REFERENCIAS.	125
ANEXOS.	134
APÊNDICES.	150

1 INTRODUÇÃO

1.1 Apresentação do Tema

A escolha em estudar a temática relacionada a detecção de mudanças para análise da produção bioenergética e pecuária em Goiás veio de encontro a assuntos estudados no Programa de Mestrado Multidisciplinar em Sociedade, Tecnologia e Meio Ambiente, da graduação em ciências biológicas e do magistério superior na área de novas tecnologias. Os conceitos relativos aos métodos de classificação coincidiram com a possibilidade do uso das Tecnologias da Informação (TI) aplicadas em questões primordialmente atuais como a produção agrícola, a proteção ambiental e o desenvolvimento sustentável.

A produção bioenergética e pecuária referem-se, respectivamente, ao perfil de área plantada (em hectares) para a cana-de-açúcar, o rebanho bovino de corte (em número de cabeças) e quantitativo da produção leiteira (em litros). Para o Estado de Goiás o plantio da cana-de-açúcar mostra-se em progressiva expansão sem deixar de lado o crescimento da pecuária em todos os municípios. Diante disso, surge uma indagação a ser respondida com a pesquisa: qual o comportamento dos municípios goianos em relação à produção bioenergética (cana-de-açúcar) e a pecuária bovina de corte e leite para os anos de 1995 e 2010?

Para responder ao problema indicado, o trabalho adotará um processo de classificação dos dados de produção para a cana-de-açúcar, pecuária bovina e de corte em 1995 e 2010. Posteriormente, será utilizado um algoritmo de detecção de mudança (DM) para que se produza um diagnóstico de mudança e não mudança dos municípios em Goiás. Nesse sentido, o termo detecção de mudança (DM) refere-se a um conjunto de ferramentas computacionais que identificam mudanças quantitativas na forma de um objeto (cana-de-açúcar, pecuária bovina de corte e leite) ou nos aspectos delineados da superfície terrestre, em diferentes datas (SINGH, 1989). Esse processo pode ser desenvolvido em três dimensões: a Pré-Classificação, a Pós-Classificação e a sinclassificação.

Na Pré-Classificação os dados de análise são classificados isoladamente o que permite gerar mapas de classes dos dois tempos (1995 e 2010) de forma independente. Aplica-se, então, o algoritmo de DM que vai produzir um mapa final para identificação das mudanças ocorridas. Na Pós-Classificação, aplica-se primeiramente o algoritmo de DM aos dados de análise, em seus respectivos tempos. Posteriormente, é feita a classificação (separação em

grupos) dos dados e, ao final do processo, um mapa de mudança permite reconhecer as modificações. **Na sinclassificação** os dados de análise, para os respectivos tempos (1995 e 2010), são analisados simultaneamente produzindo um único mapa de características. Aplica-se, então, o algoritmo de DM, o que resultará em um cruzamento de informações que permite comparar todos os dados para a obtenção de um mapa de mudança.

Em qualquer dimensão de classificação, já citada anteriormente, é importante ressaltar que o termo classificação consiste na busca do reconhecimento de componentes em função de um critério estabelecido, agrupando em classes que apresentam aspectos ou padrões de similaridade. A ideia final será a produção de um mapa de mudança com grupos ou temas definidos em termos quantitativos para serem analisados e interpretados de acordo com a necessidade e intenção da pesquisa (FLORENZANO, 2011). O processo de classificação temporal pode ser realizado de duas formas: por um método supervisionado ou não supervisionado.

Em um método supervisionado os grupos que serão classificados são previamente definidos por um supervisor externo. Nesse caso, o analista fornecerá amostras (dados) das classes representativas que não, necessariamente, sejam homogêneas. É importante ressaltar que todo o processo precisa acontecer baseado em regras estatísticas pré-estabelecidas. Já no método não supervisionado os grupos a serem classificados não são pré-determinados, ou seja, tal técnica não possui a interferência de um analista ou supervisor externo para fornecer as classes de treinamento o que a tornará menos subjetiva na obtenção dos resultados. Conclusivamente, as classes são definidas a posteriori, como um resultado da análise (FLORENZANO, 2011).

A pesquisa realizada utiliza uma Rede Neural Artificial (RNA), cujos estudos tiveram início em 1943, com a publicação de artigos científicos de McCulloch e Pitts que demonstraram uma similaridade entre a aprendizagem de neurônios, com o processo computacional de aprendizagem. Os estudos sobre RNA tiveram avanços com a criação de um modelo denominado Perceptron, proposto por Rosenblatt (1958), no qual foi demonstrado que as redes neurais de McCulloch poderiam ser treinadas para classificar padrões em classes linearmente separáveis (uma única camada de neurônios) (RUSSEL e NORVIG, 1995).

Os estudos relacionados a RNA tiveram avanços consistentes na década de 80, com a criação de arquitetura de redes neurais mais complexas, constituídas por várias camadas, capazes de resolver problemas não linearmente separáveis. Para tais modelos, a determinação

do número de camadas utilizada influencia, diretamente, na capacidade de aprendizado da rede (CARVALHO e LUDEMIR, 1998).

Para realizar o aprendizado de uma RNA, o treinamento da rede pode ocorrer de duas formas principais: o aprendizado supervisionado e o não supervisionado. Para que aconteça uma aprendizagem supervisionada, inicialmente serão definidos a estrutura e os parâmetros de treinamento. Em seguida, a rede neural deve ser treinada. A partir daí, estará pronta para ser utilizada. Nesse caso, o processo é dirigido por um supervisor (professor) que fornece à RNA uma resposta desejada para aquele vetor de treinamento. Contraditoriamente, na aprendizagem não supervisionada, a rede neural também deverá receber prévio treinamento. Contudo, para esse modelo, não há exemplos rotulados da função a ser apreendida pela RNA, ou seja, não existe o direcionamento de um supervisor (professor) para conduzir o treinamento da rede neural (HAYKIN, 2001).

Na atualidade, os estudos relacionados ao processo de aprendizado não supervisionado mostram-se de grande relevância em pesquisas sobre RNA e, em especial, destaca-se um modelo que foi utilizado no presente trabalho: o Self-Organizing Feature Maps (SOFM) ou mapa auto-organizado de características. A utilização de redes com aprendizagem não supervisionada pode ser justificada pela necessidade de o sistema ser capaz de extrair por si só a informação necessária para realizar o processo de agrupamento dos dados sem (ou com mínima) a intervenção de um operador humano. Esta propriedade recebe o nome de auto-organização. Uma rede não supervisionada deve descobrir por si só os padrões, características, regularidades, correlações ou categorias implícitas nos dados de entrada e codificá-las na saída (BECKER, 1991).

Conforme explica Becker (1991), no aprendizado não supervisionado auto-organizado, a rede deve ajustar-se às regularidades estatísticas dos dados de entrada e desenvolver habilidade de formar representações internas para codificar as características de entrada e, assim, criar automaticamente novas classes.

É importante explicar que, a aprendizagem de uma rede neural não supervisionada fundamenta-se em dois mecanismos básicos: competição e correlação. No processo de competição as estruturas neurais competem entre si pelo direito de responder a um determinado estímulo sensorial de entrada. Fundamentalmente existem três elementos que caracterizam o aprendizado competitivo:

1º Existe um conjunto de neurônios idênticos, ligados por valores de conexões sinápticas de valores distribuídos de modo aleatório.

2º Existe um valor Máximo bem definido para ativação dos neurônios.

3º Existe um mecanismo que permite que os neurônios entrem em competição pelo direito de permanecerem estimulados.

No aprendizado competitivo, entradas possuindo alguma semelhança tendem a excitar o mesmo neurônio na saída (Barreto 2001).

No processo de correlação a estrutura neural se auto-organiza de tal forma a extrair a informação relevante a partir de correlações existentes nos dados sensoriais. Este último tipo de mecanismo de aprendizagem é comumente chamado de aprendizagem hebbiana (HEBB, 1949). A pesquisa em foco utilizou mapas auto-organizados de características, adotando o mecanismo competitivo para a obtenção dos resultados. As ferramentas para a realização do trabalho baseiam-se em um modelo de RNA com mecanismo de aprendizagem não supervisionada, o qual será utilizado na fase de classificações durante o processo de detecção de mudança por sinclassificação para o estudo da produção bioenergética e pecuária em Goiás.

A referida dissertação visa a proposição e utilização de redes neurais artificiais com aprendizagem não supervisionada, que sejam capazes de aprender demonstrando eficácia na análise de dados disponibilizados pelo Instituto Brasileiro de Geografia e Estatística (IBGE) relacionados ao setor produtivo em Goiás. As principais contribuições desse trabalho podem ser assim, resumidas:

a) Estudo da dinâmica dos modelos de redes neurais artificiais não supervisionadas, para o reconhecimento e detecção de mudanças temporais; b) Aplicação do processo de detecção de mudança utilizando sinclassificação para análise de dados de produção bioenergética e pecuária do Estado de Goiás; c) Utilização de um modelo de RNA com aprendizagem não supervisionada e auto-organizada, capaz de lidar com uma sequência bitemporal para analisar e extrair informações concretas relacionadas ao setor bioenergético e pecuária em Goiás.

As pesquisas, sobre redes neurais artificiais são importantes porque visam desenvolver modelos matemáticos, não necessariamente ligados a área biológica, que podem desempenhar várias funções. Dentre as aplicações, pode-se destacar algumas:

a) Processamento de imagens de sensores remotos (TODT, 1998); b) Processamento de dados estatísticos oficiais (BARRETO, 1998); c) Reconhecimento e classificação de padrões urbanos e/ou rurais (KIEL, 2008); d) Estudo de comportamento biológico entre diferentes espécies (FRANCISCO, 2004); e) Robótica e controle de equipamentos médicos como braços mecânicos utilizados em cirurgias reparadoras (NUNES, 2003); f) Análise de Grupos (MENKE, 2012); g) Processamento de sinais elétricos (marcapassos cardíacos)(ROGAL JÚNIOR, 2008);

Faz-se necessário enfatizar que um determinado sistema que utiliza RNA pode usar de forma única ou intercalada, as funções acima referenciadas. É importante ressaltar que em sistemas nos quais se utilizam algoritmos não supervisionados, normalmente, muito pouco se conhece a respeito do conjunto de dados de entrada. O tipo de informação que uma rede não-supervisionada extrai dos dados de entrada depende de sua arquitetura e dinâmica, existindo uma infinidade de tarefas nas quais se aplicam tais redes. Nos mapas de características auto-organizáveis (self-organizing maps) as unidades de saída estão dispostas de acordo com uma forma geométrica específica. A partir disso, as unidades de saída mapeiam os padrões de entrada em diferentes pontos neste arranjo, preservando relações de vizinhança existentes na distribuição de entrada. Com isso, padrões semelhantes ativam unidades de saídas próximas (GRAY, 1984).

O trabalho está organizado em seis sessões, sendo que, a primeira sessão apresenta uma introdução ao tema de estudo mostrando conceitos sobre detecção de mudança temporal e suas dimensões de aplicação, definições sobre redes neurais artificiais e os métodos de aprendizagem de rede supervisionados e não supervisionados e, apresenta uma ideia geral sobre um tipo específico de rede neural denominada mapa de características auto-organizáveis ou SOFM. Apresentam-se, ainda, as contribuições e aplicações relacionadas ao tema de estudo.

A segunda sessão faz descrição relacionada ao problema a ser pesquisado e os objetivos propostos.

A terceira sessão apresenta as orientações conceituais básicas relacionadas ao estudo, tais como: detecção de mudanças temporais, os métodos de análise supervisionada e não supervisionado, redes neurais artificiais (RNA) e os mapas auto-organizáveis de características (SOFM).

A quarta sessão faz uma descrição sobre os materiais e métodos da pesquisa e, também, descreve o Estado de Goiás e suas regiões, caracteriza o cerrado brasileiro e a metodologia adotada no estudo.

A quinta sessão apresenta os resultados obtidos com a pesquisa e as discussões relacionadas ao tema estudado.

E, finalmente, na sexta sessão, apresentaremos as conclusões e considerações finais do trabalho, os pontos positivos e negativos de destaque e os possíveis trabalhos que poderão ser desenvolvidos no futuro.

2 APRESENTAÇÃO DO PROBLEMA

2.1 A produção sucroalcooleira e a pecuária em Goiás

Nesse contexto, dados oficiais relativos ao setor bioenergético (cana-de-açúcar) e pecuária de corte e leiteira dos municípios goianos serão utilizados na aplicação de detecção de mudança com ênfase nos sistemas auto-organizáveis como método de classificação para verificar o comportamento produtivo de cana-de-açúcar e pecuária no Estado. O trabalho será desenvolvido dentro de um padrão bitemporal utilizando sinclassificação para que seja possível monitorar temporalmente as modificações relativas ao comportamento da produtividade nos municípios goianos. Ao final espera-se ser possível afirmar que, nas últimas décadas, a cultura canavieira tem provocado contínuas transformações no perfil produtivo em Goiás. Dentro dessa ótica de mapeamento da produção agrícola e pecuária nos municípios, a pesquisa mostra-se de grande utilidade, tanto do ponto de vista ambiental, como social, econômico e tecnológico.

Na última década, a perspectiva do vertiginoso crescimento mundial pela produção e consumo de alimentos contribuíram para uma grande discussão sobre a pauta do crescimento econômico com sustentabilidade e da expansão produtiva do setor agropecuário brasileiro. Outro item da discussão tem se pautado na possibilidade crescente da demanda por matéria-prima para a produção energética “limpa”, principalmente, o etanol. No caso do Brasil, a atenção mundial se volta rapidamente uma vez que o país possui extensão territorial capaz de atender tanto a produção de alimento quanto a produção de energia (SILVA, 2010).

De acordo com Lima e Garcia (2011), o aumento da produção canavieira, em primeiro lugar, está associado ao intenso movimento de expansão da agroindústria canavieira em direção às novas regiões (fronteiras agrícolas), como o Estado de Goiás. Em segundo lugar, ele se deve à dinâmica expansiva da instalação do parque industrial etanol/açúcar em Goiás, que foi visto de modo diferenciado. Vale ressaltar, ainda, que a região Centro-Oeste é uma das que possui as maiores taxas de crescimento da produção da cana-de-açúcar no país, de acordo com dados disponibilizados pelo Instituto Brasileiro de Geografia e Estatística (IBGE). Essa bolha de crescimento já ocorreu com a soja, com o milho e, no século XXI, a cultura canavieira tornou-se maior em atratividade para os produtores agrícolas dos estados do Centro-Oeste.

Em Goiás, o setor sucroalcooleiro (etanol/açúcar) beneficiou-se de um modelo no qual a produção agrícola foi marcada pela grande intervenção e atuação do poder público na organização de interesses e na implantação de políticas públicas que garantissem infraestrutura necessária para viabilizar os investimentos da iniciativa privada. Observa-se, atualmente, que essa política continua predominante e os resultados no Estado já são nítidos (LIMA e GARCIA, 2011). Esse processo foi potencializado com a criação e execução do Proálcool, na década de 1970.

Em 14 de Novembro de 1975, o decreto presidencial nº 76.593 criava o Programa Nacional do Álcool (Proálcool) que tinha como objetivo principal reduzir a dependência brasileira da importação de petróleo. A medida teve impacto positivo pois permitiu que 10 milhões de carros a gasolina a menos passassem a circular no Brasil. A produção de álcool no Brasil no período de 1975-1976 foi de 600 milhões de litros; no período de 1979-1980 foi de 3,4 bilhões de litros e, de 1986-1987 chegou ao auge, com 12,3 bilhões de litros. Conforme afirma Barros (2007), O etanol combustível, tinha nos altos preços da gasolina um decisivo incentivo para a sua produção. Isso foi tão expressivo que em 1985, dos carros fabricados no país, 95,8% eram movidos a álcool.

Apesar de toda a empolgação relacionada ao Proálcool, ocorreram inúmeras críticas à sua implantação. Algumas se baseavam no fato de que as áreas de cultivo de cana-de-açúcar aumentariam exageradamente, o que poderia provocar diminuição de áreas agrícolas para a produção de alimentos. Além disso, a sazonalidade, na época, foi também um grande fator negativo para a continuidade do projeto (ANDRADE et al., 2009). A crise de abastecimento de álcool do fim dos anos 1980 afetou, significativamente, a credibilidade do Proálcool e da capacidade governamental de sustentá-lo. A explicação para tal fracasso viria a ser justificada a partir da redução dos preços internacionais do petróleo e a elevação dos preços do açúcar, logo, para os usineiros seria mais lucrativo exportar açúcar do que produzir álcool. Essas foram as causas que, oficialmente, levaram a decadência do programa nacional do álcool.

Mesmo diante de um cenário desanimador, a estabilidade econômica alcançada no início dos anos 90 instaura um novo ciclo de crescimento da produção de lavoura da cana-de-açúcar que tende a abranger territórios de todo o país, entre eles o Cerrado e o Estado de Goiás. Essa expansão é perceptível quando se avalia que no período de 1995 a 2006, a lavoura de cana cresceu 47,9%, atingindo uma comercialização que chegou a quase 20 bilhões de reais em 2006, valor máximo alcançado por uma cultura agrícola no Brasil (BRASIL, 2006,

p.151).

A consolidação econômica veio no início dos anos 2000 quando da necessidade de oferta de álcool em larga escala nacional visto que a indústria automobilística diante da tecnologia dos motores bicombustíveis revolucionou o mercado brasileiro com a produção do carro bicombustível (movidos a álcool ou gasolina). Tal fato daria novo fôlego à indústria sucroalcooleira provocando aumento do consumo interno de álcool e, conseqüentemente, o crescimento da cultura canavieira no Estado de Goiás (GOIÁS, 2010).

Outro aspecto que vem justificar o grande avanço da cultura canavieira no Estado de Goiás e região Centro-Oeste, foi a aprovação da Lei de Zoneamento Agro Ecológico da cana-de-açúcar, regulamentado em 2009 pelo Governo Federal, que veta a produção de cana-de-açúcar na Bacia Amazônica, no Pantanal e na Bacia do Alto Paraguai. Loyola (2010), afirma que tal regulamentação favoreceu a produção de cana-de-açúcar em Goiás em função das restrições de crescimento exibidas pela lei.

Adotando o mesmo raciocínio para a pecuária em Goiás uma questão pode ser discutida: a cana-de-açúcar expande e a pecuária bovina de corte e leite também mostra-se como atividade forte e crescente em todos os municípios. Como isso vem acontecendo?

A criação de gado em Goiás surge da necessidade de uma cultura de subsistência uma vez que o fim do ciclo do ouro, na segunda metade do século XIX, torna as terras goianas pouco atrativas aos portugueses. A pecuária ganha força e desenvolve-se de forma acelerada de 1822 a 1890. A partir de 1890, até metade do século XX, a pecuária bovina de corte e leite continua pujante e ganha o incremento da agricultura na economia regional. A partir de 1950, a região goiana inicia um processo contínuo de produção de alimentos para suprir a demanda do país e, o governo goiano percebe, então, a possibilidade de incremento da economia por meio das exportações. Esse processo iniciaria com produtos oriundos da pecuária, principalmente, a carne e o leite (PAULA, 2011).

Conforme explica Luz (2001), somente na década de 1960, Goiás experimentou uma fase na qual a produção extensiva e sem capital dava lugar à produção mecanizada, tecnológica e com farto capital. Na esfera estadual, o Governador Mauro Borges criou o Plano de Desenvolvimento Econômico de Goiás e a Reforma Administrativa para dar dinamismo ao plano (SILVA, 2003).

No âmbito federal, Goiás foi beneficiado por alguns programas de incentivo. Na sua

região setentrional, o Estado foi incluído no contexto da Amazônia Legal, sendo objeto de planejamento e investimentos, através da SUDAM (Superintendência do Desenvolvimento da Amazônia); no lado centro meridional os investimentos vieram da SUDECO (Superintendência do Desenvolvimento do Centro-Oeste). Estes programas federais tiveram a função de estruturar o Estado para o avanço da produção agrícola e da pecuária.

A pesquisa referente ao setor agropecuário em Goiás ficou sob a responsabilidade da EMBRAPA (Empresa Brasileira de Pesquisa Agropecuária), que conquistou avanços significativos para a época. Em toda a região goiana foram implantadas unidades de pesquisa e campos experimentais. A intenção era alcançar, por meio tecnológico, resultados expressivos na produção de grãos e criação de gado em áreas de cerrado. Contudo, o período do governo militar, na década de 70 do século XX, foi impulsionado por uma onda de otimismo por parte das esferas governamentais, com crescimento médio na casa dos 10% anuais. Surge o GOIASRURAL, um dos maiores programas de desenvolvimento da produção agropecuária do mundo. O governo federal tinha urgência na ampliação da produção agropecuária para suprir a necessidade que assombrava o país de substituição de importação de produtos básicos alimentares (FERREIRA, 2004).

Para Falconi (2005), a pecuária goiana sofre expansão acentuada a partir de 1970. O autor relata que, de acordo com dados da SEPLAN (Secretaria de Planejamento e Desenvolvimento do Estado de Goiás) em 1970, o rebanho bovino de Goiás e Tocantins juntos era de 7.792.839 cabeças; em 1995/1996, somente em Goiás, o rebanho já era de 16.488.399 cabeças; em 2000, o rebanho era de 17.932.000 milhões de cabeças; em 2010 já atingia a casa de 21.348.000 milhões de cabeças. A produção de leite não ficou atrás: em 2000 foram 1.844.000 litros produzidos; em 2005 foram 2.648.599 litros e, em 2010 foram 3.194.000 litros.

Diante do exposto, é nítido que o Estado de Goiás, a partir da estabilidade econômica alcançada em 1994, com a nova moeda denominada real, tem sido um destino seguro aos investimentos produtivos. Segundo dados da Pesquisa de Intenção de Investimentos, realizada pela Secretaria de Planejamento e Desenvolvimento do Estado de Goiás (SEPLAN-GO) em junho de 2012, por meio da Superintendência de Estatística, Pesquisa e Informação (SEPIN), estima-se que, até 2015, o Estado de Goiás receba uma estimativa de R\$ 27,8 bilhões de intenção de investimentos no Estado através de mais de 780 projetos de implantação e expansão. Estes investimentos estão apresentados por atividade econômica e distribuídos por

Região de Planejamento. Desse total de investimentos previstos, constata-se que R\$ 9,45 bilhões (34,0%) correspondem ao segmento Sucroenergético (SEPLAN, 2012).

Portanto, é nítido que a cana-de-açúcar e a pecuária de corte e leite em Goiás contribuem de forma significativa para o crescimento econômico do Estado. Diante disso, qual o comportamento dos municípios goianos em relação a produção bioenergética (cana-de-açúcar) e pecuária de corte e leite em 1995 e 2010?

2.2 A Geotecnologia e as ferramentas que facilitam a análise de dados de produção

As geotecnologias são definidas como um conjunto de tecnologias (Sistemas de Informações Geográficas - SIG, geoprocessamento, cartografia digital, sensoriamento remoto, Sistema de Posicionamento Global), cuja fundamentação principal baseia-se na coleta, processamento, análise e visualizações de informações com referência geográfica, a partir de uma estrutura técnica e metodológica que se mostra fundamental para a elaboração de bancos de dados georreferenciados utilizados na quantificação de fenômenos naturais diversos o que permitirá ao pesquisador ter uma visão mais abrangente do ambiente numa perspectiva geossistêmica (GUERRA, 2006).

Define-se por dados geográficos as informações ou atributos espaciais que descrevem a forma e localização de um objeto, associado aos atributos descritivos deste mesmo objeto (CHORLEY, 1975). Um sistema capaz de realizar o tratamento computacional desses dados geográficos é denominado sistema de informação geográfica – SIG (CHORLEY, 1974). Logo, os SIG são sistemas capazes de agrupar, numa única base de dados, informações espaciais provenientes de dados cartográficos, dados de censo e de cadastro urbano e rural, imagens de satélites e modelos numéricos de terrenos. Ainda, essas informações podem ser integradas, por meio de algoritmos de manipulação, para gerar mapeamentos derivados o que possibilita consultar, recuperar, visualizar e imprimir o conteúdo da base de dados geocodificados (FORESMAN, 1998).

Todas as ferramentas tecnológicas disponíveis na atualidade podem e devem ser utilizadas na análise de dados de produção de modo que variáveis numéricas quantificadas por Institutos Especializados possam ser transformadas em informações úteis ao planejamento e gestão quer seja, rural ou urbana, em esferas municipais, estaduais e federais. No Brasil, pode-se destacar o Instituto Brasileiro de Geografia e Estatística – IBGE e as Secretarias de

Planejamento dos Estados e Municípios – SEPLAN, responsáveis pela quantificação de dados rurais e urbanos que, na sua grande maioria, podem ser inúteis caso não possibilitem tomada de decisões e estratégias de gestão pública que venham possibilitar a melhoria da qualidade de vida das pessoas (CÂMARA et al., 2001).

Diante do exposto, os autores acima citados, demonstram que a utilização das geotecnologias torna-se, cada vez mais, reconhecidas enquanto ferramentas que disponibilizam instrumentos capazes de otimizar estratégias de planejamento, gestão e monitoramento em seus diversos aspectos. Seu aproveitamento é multidisciplinar, desde aplicações científicas como nos caso dos boletins meteorológicos, na cartografia, geografia, economia, biologia e até no agronegócio. Com tendência de expansão, as tecnologias servem continuamente de parâmetros confiáveis para pesquisas agrícolas e urbanas em abordagens de micro e macroanálises.

Tal situação faz com que a demanda por dados seja contínua e crescente em todas as escalas da administração, desde o nível global ao local, do mundial ao municipal (CÂMARA, 2001). Nesse contexto de necessidades por informações que permitam melhorar planejamentos, monitorar e gerir recursos naturais, cidades e políticas públicas, é urgente abordar a questão das sustentabilidades de forma que as ações do presente tenham seus impactos negativos minimizados no futuro.

A pesquisa proposta justifica-se diante da perspectiva de utilização de dados oficiais referentes ao setor produtivo em Goiás para a aplicação da tecnologia de modo a caracterizar o comportamento nos municípios goianos e, paralelamente, comprovar se a utilização de detecção de mudanças mostra-se eficaz como ferramenta de análises de variações produtivas relacionadas à cultura canavieira, pecuária bovina e leiteira no Estado. A escolha das variáveis produtivas a serem pesquisadas (cultura canavieira e pecuária bovina e leiteira) acontece diante do grau de importância econômica para Goiás, haja vista que, historicamente, o Estado desenvolve e consolida-se, economicamente, a partir das culturas agrícolas e da pecuária.

A posição geográfica privilegiada aliada a características físicas favoráveis são facilitadores para a expansão dessas atividades (cultura canavieira e pecuária). O relevo de baixa declividade e terras planas (chapadões), a abundância de água (com três bacias hidrográficas: Tocantins/Araguaia, São Francisco e Paraná), solo do tipo latossolo, com predominância de material mineral e duas estações climáticas bem definidas (um período chuvoso, que vai de outubro a abril, e um período de seca, que vai de maio a setembro)

tornam a região centro-oeste, com destaque para Goiás, propícia ao desenvolvimento da agricultura e da pecuária (SEPLAN, 2009).

Nesse contexto, vale ressaltar que o setor canavieiro e a pecuária bovina de corte e leite no Estado contribuem com 13,9 % do perfil econômico total e, dele, estão inseridos na cadeia produtiva vários setores ligados à agroindústria, o que inclui a produção de carnes, leite e outros itens da indústria como a produção canavieira e sucroalcooleira. Mesmo diante de contínua industrialização, o setor agropastoril continua sendo a mola propulsora do sistema econômico em Goiás (SEPLAN, 2009).

Para reforçar tal logística de crescimento, o Estado possui programas de incentivo próprios ao desenvolvimento econômico que contribuem, de forma significativa, para a expansão, modernização e diversificação dos setores agropecuários e industriais, ampliando os investimentos, estimulando a utilização de novas tecnologias, assegurando a formação de mão-de-obra qualificada o que vem promover maior competitividade e desempenho relativos à economia goiana (SEPLAN, 2009).

Quanto aos incentivos financeiros, destaca-se, também, aqueles geridos pelo Governo Federal aos Estados como o FCO (Fundo Constitucional do Centro-Oeste), criado em 1988, com o intuito de contribuir para o desenvolvimento econômico e social do Centro-Oeste brasileiro. O aporte permanente dos recursos do Fundo, pela União, correspondem a 29%. Tal percentual permite aos Estados realizarem financiamentos de longo prazo para os setores econômicos, o que propicia novas perspectivas de investimentos para os empreendedores comprometidos com a dinamização, modernização e expansão das economias regionais (SEPLAN, 2009).

2.3 Objetivos

2.3.1 Geral

Mensurar a eficácia da aplicação de detecção de mudanças temporais, como proposta metodológica, para a caracterização do setor bioenergético (cana-de-açúcar) e pecuária de corte e leiteira, dos municípios goianos. Espera-se que o processo de detecção de mudança mostre que durante os dois tempos (1995 e 2010) pesquisados houveram variações quanto aos indicadores de produção. A caracterização deve mostrar em quais municípios ocorreu

acrécimo ou decréscimo de produção. Isso será possível a partir do processo de sinclassificação com a utilização de uma rede neural artificial (SOFM) como metodologia de classificação.

2.3.2 Específicos

Caracterizar o comportamento das variações produtivas dos municípios goianos, em relação a produção canavieira, pecuária de corte e leite, entre os anos de 1995 e 2010. Espera-se que os resultados possam mostrar se há maior quantidade de municípios grandes produtores, médios ou pequenos produtores, dentre outras possibilidades. O tempo utilizado justifica-se por dois fatores primordiais: a estabilidade econômica alcançada no Brasil em meados de 1990 e, também, a reorganização e expansão do setor sucroalcooleiro face à necessidade de atendimento à indústria automobilística com a chegada dos motores bicombustíveis.

Validar os resultados por meio da avaliação das classificações realizadas no processo de detecção de mudanças;

3 ORIENTAÇÕES CONCEITUAIS

3.1 Detecção de mudanças

Análise de mudança temporal significa detectar mudanças ocorridas em um espaço ou paisagem, durante um determinado intervalo de tempo. Em outra linguagem, a detecção de mudanças se refere ao reconhecimento de modificações ocorridas na superfície terrestre, com o passar do tempo (LORENA, 2001).

É importante ressaltar, ainda, que dados de séries temporais podem ser utilizados em diversas áreas do conhecimento. Nas ciências econômicas é possível fazer análise das variações de preços de um determinado produto agrícola; na medicina para o monitoramento do ritmo cardíaco do paciente; na epidemiologia para quantificação de novos casos de uma doença, em um surto epidêmico da mesma; na geotecnologia para quantificar, a partir de dados vetoriais, as mudanças ocorridas em uma determinada região de interesse e outros (PACKARD, 1980).

Há, basicamente, dois tipos de séries temporais: o discreto e o contínuo. A seguir, uma descrição conceitual sobre cada um deles.

3.1.1 Série discreta

Uma série temporal é considerada discreta quando as observações são feitas em tempos específicos, geralmente, equiespaçados. Sendo o conjunto $T = \{t_1, t_2, \dots, t_n\}$ a série temporal será denotada por $\{X_t : t \in T\}$. De forma simplificada pode-se fazer $T = \{1, 2, 3, \dots, n\}$ (MONTEIRO, 2006). Há séries que são inerentemente discretas como, por exemplo, a quantificação de mudanças em um modelo bi-temporal (dois tempos distintos). Nesse caso, as mudanças detectadas serão avaliadas apenas para os dois períodos de interesse da pesquisa.

3.1.2 Série contínua

Uma série temporal é dita contínua quando as observações são feitas continuamente no tempo. Ao definir o conjunto $T = \{t: t_1 < t < t_2\}$, a série temporal será denotada por $\{X(t): t \in T\}$. É importante ressaltar que séries contínuas podem ser discretizadas de acordo com os objetivos da pesquisa (MONTEIRO, 2006).

A pesquisa adotou como fundamentação matemática a utilização de uma série discreta com dois tempos distintos (1995 e 2010) e um método univariado. Este método de otimização é classificado como um método sequencial ou método do fator único ou estratégia um fator de cada vez. Neste método, fixam-se todos os fatores que estão sendo pesquisados em um certo nível, menos um deles. Este último é então variado até que se encontre a melhor resposta, passando então esta condição a ser fixada e um novo fator sofre variação. O processo se repete até que todos os fatores tenham sido adequados para fornecer a melhor resposta. O trabalho adotou como fator único o indicador de produção para os municípios goianos relativos a cana-de-açúcar, pecuária bovina de corte e leite.

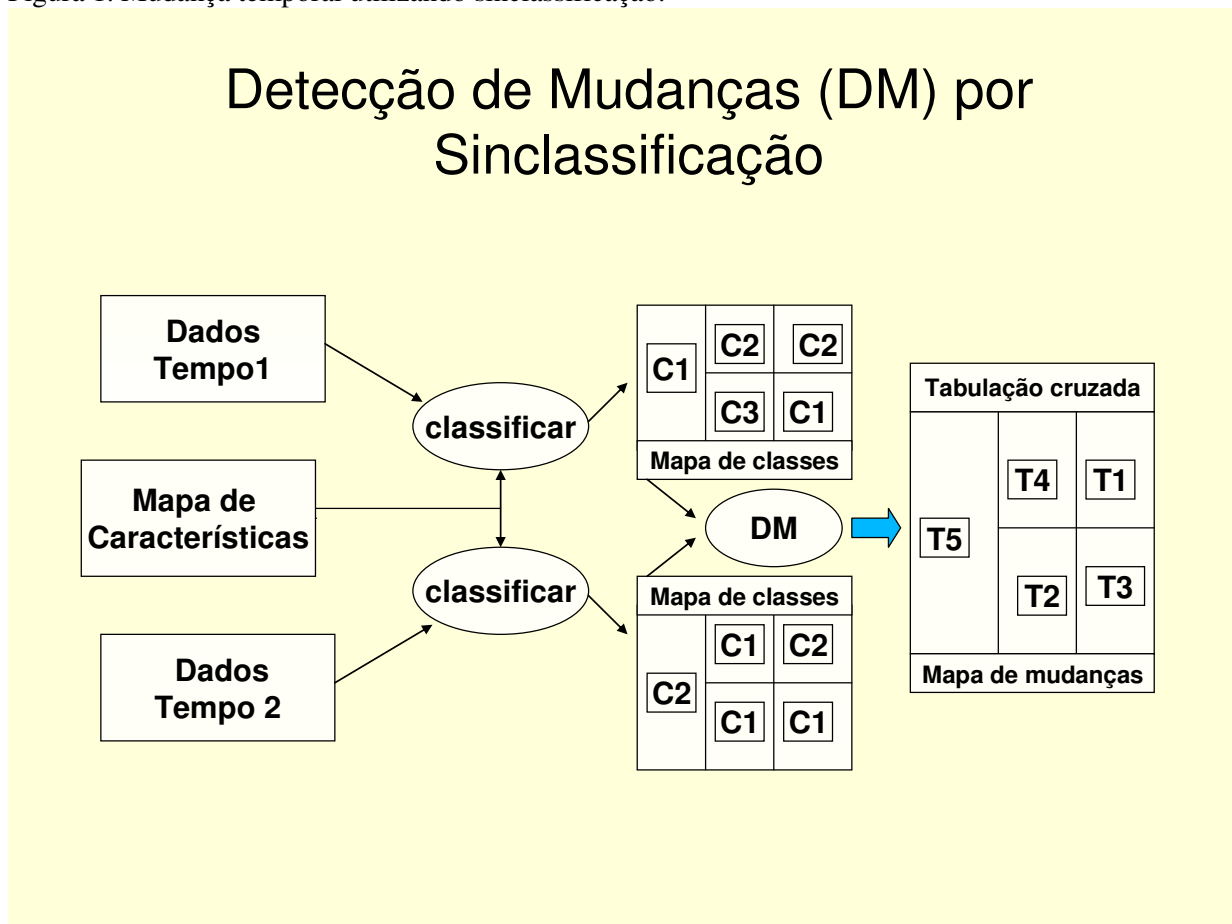
3.2 Classificação e mudança temporal

A classificação é um procedimento de identificação de classes ou grupos que possuem características similares (RICHARDS, 2006). Nesse sentido, utiliza-se a palavra característica para identificar padrões para um determinado descritor. Conforme afirma Gonzalez e Woods (2010), uma classe de padrões compreende um grupo padronizado que possui características (como tamanho, cor, escala e outros) em comum. Os grupos são representadas por $x_1, x_2, x_3, \dots, x_n$ onde n indica o número de grupos que se pretende definir. A identificação de padrões a determinadas classes ou grupos deve ser feita de forma automática por meio de ferramentas computacionais (a pesquisa adotou uma rede neural artificial) que minimizem ao máximo a possibilidade de erros.

Nessa abordagem, Florenzano (2011), afirma que a classificar significa buscar o reconhecimento automático de componentes, em função de um critério de decisão já estabelecido, agrupando em classes que apresentam aspectos ou padrões de homogeneidade. A intenção final será a produção de um mapa temático com as classes ou temas bem definidos em termos quantitativos para uma posterior análise e interpretação.

Em uma análise bi-temporal estabelecer-se-á dois tempos específicos para o estudo (1995 e 2010) e o algoritmo de classificação determinará padrões para a definição das classes ou grupos a serem pesquisados. Em uma abordagem de sinclassificação, o treinamento será realizado de forma que os dados dos dois tempos determinados sejam analisados de forma simultânea (tabulação cruzada). Ao final, será possível produzir informações que possibilitem determinar ou não a ocorrência de mudanças ou modificações temporais (Figura 1).

Figura 1. Mudança temporal utilizando sinclassificação.



Fonte: Autor (2013), adaptado de SILVA (2003).

Tomando como exemplo a Figura 1, após a classificação simultânea para os dois tempos ter sido realizada, será possível determinar o número de classes (grupos) e as mudanças ocorridas ao longo do tempo. Por exemplo, em $T_1: C_2 \rightarrow C_2$; em $T_2: C_3 \rightarrow C_3$; em $T_4: C_2 \rightarrow C_1$; em $T_5: C_1 \rightarrow C_2$ e, assim, sucessivamente. Conforme descrito anteriormente, a região considerada T_1 indica que, onde havia classe 2, não houve modificação após a detecção de mudança; para a região T_4 o que era considerado classe 2 modificou-se para classe 1, após a detecção de mudança; para a região T_5 o que era considerado classe 1 modificou-se para

classe 2 e, assim, sucessivamente.

A identificação de mudança do indicador de produção dos municípios goianos será feita a partir de um processo de agrupamento dos dados, baseando-se na homogeneidade existente entre eles. Cada grupo de dados com características comuns entre si compõem um grupo. Para uma análise de resultados, os dados de um mesmo grupo serão mais similares comparando com os pertencentes a grupos diferentes. Agrupar os dados é um meio facilitador para a compreensão dos mesmos. O processo de classificação realizado pela rede neural artificial é considerado não supervisionado, uma vez que a estruturação e as propriedades que os tornar semelhantes não são conhecidas (JAIN e DUBES, 1988).

Procedimentos de classificação podem ser realizados de forma supervisionada, na qual as classes (grupos) são definidas, prioritariamente, pelo analista e, também de forma não supervisionada, na qual as classes são, posteriormente, definidas e estabelecidas como resultado da análise (FLORENZANO, 2011). Na sequência, uma descrição sobre as principais diferenças existentes entre os métodos supervisionado e não supervisionado.

3.2.1 Método supervisionado

O método de classificação supervisionada é desenvolvido com base em amostras de treinamento, ou seja, os dados são classificados, segundo regras predeterminadas, para obtenção de classes ou grupos de interesse da pesquisa (CRÓSTA, 1993).

Essa técnica de classificação, portanto, exigirá do analista um controle sobre o processo, acarretando pontos positivos e negativos. Por exemplo, o analista consegue identificar possíveis erros, pela análise da amostra de treinamento; por outro lado, o analista define a estrutura de classificação dos dados estabelecendo, previamente, as classes ou grupos de informação (JENSEN, 1996).

3.2.2 Método não-supervisionado

Este tipo de classificação é realizado sem que um analista especifique os padrões que irão definir as classes ou grupos a serem analisados. O princípio geral é aquele em que a máquina ou o software utilizado será capaz de identificar, sozinho, as classes dentro de um

conjunto de dados (CRÓSTA, 1993).


De acordo com Daianese (2001), O método é dito não supervisionado quando o classificador não utiliza, a priori, nenhum conhecimento sobre as classes existentes e define, sem a interferência do analista, a estratificação da cena, atribuindo a cada feição uma determinada classe. Tal abordagem corresponde à técnica de segmentação de grupos, onde os mesmos são divididos em certas classes sem conhecimento prévio. Neste tipo de classificação, o algoritmo baseia-se na análise de grupos ou dados com características comuns, ou seja, são identificados no espaço de atributos os clusters ou grupos, com características similares.

3.2.2.1 Redes Neurais Artificiais (RNA)

Redes Neurais Artificiais (RNA) são técnicas computacionais que propõem o processamento de informações baseando-se na organização física do cérebro humano. O cérebro é comparado a um processador extremamente complexo cujo processamento é realizado de maneira paralela. Seus neurônios são os responsáveis pela realização desse processamento (ALECRIM, 2004) e devido a sua imensa quantidade, a velocidade de resposta é mais alta do que a de qualquer computador já fabricado pela indústria. É estimada a existência de cerca de 10 bilhões de neurônios no córtex humano e cerca de 60 trilhões de sinapses (HAYKIN, 2001, p.32).

O neurônio é a unidade básica do cérebro. “Ele recebe e combina estímulos de vários outros neurônios (muitas entradas), e transmite apenas uma saída” (MEDEIROS, 1999). Os dendritos são conexões que recebem os estímulos enviados por outros neurônios e os axônios são responsáveis por transmitir os estímulos a outras células (KOVÁCS, 1996). As sinapses são as unidades estruturais de conexão entre os neurônios e responsáveis por transportar os impulsos entre diversos neurônios. Em RNAs, as sinapses são as responsáveis por inibir ou excitar um neurônio. (HAYKIN, 2001, p. 32-33). A Figura 2 ilustra os componentes de um neurônio biológico similares aos de uma RNA.

Figura 2: Estrutura do neurônio humano



Fonte: CARVALHO (1998).

De acordo com os fundamentos propostos por Haykin (2001), em um aspecto mais amplo, uma RNA é uma máquina construída para simular a maneira como o cérebro realiza uma ação específica ou desempenha função desejada. A rede é usualmente construída e organizada por componentes eletrônicos ou é simulada por programação em uma máquina digital.

O autor ainda diz que

Para alcançarem bom desempenho, as redes neurais empregam uma interligação maciça de células computacionais simples denominadas “neurônios” ou “unidades de processamento”. As redes neurais são também referidas na literatura especializada como neurocomputadores, redes conexionistas, processadores paralelamente distribuídos e outros (HAYKIN, 2001, p.28).

Para Haykin (2001), uma rede neural é similar ao cérebro em dois aspectos:

1) o conhecimento adquirido pela rede, a partir de seu ambiente, por meio de um processo de aprendizagem e, 2) Conexões estabelecidas entre os neurônios, denominadas de pesos sinápticos, utilizados para armazenar o conhecimento adquirido (HAYKIN, 2001, p.28).

Um aspecto é crucial: para que uma rede neural “aprenda” é empregado um algoritmo de aprendizagem, cuja função será modificar os pesos sinápticos da rede de uma forma ordenada para alcançar um objetivo desejado. Há várias formas para se configurar uma rede neural, modificando suas topologias, o que vai aumentar sua eficiência para que a mesma forneça os resultados desejados.

Haykin (2001) explica, também, que a base de uma rede neural configura-se a partir de seus neurônios artificiais que são unidades de processamento de informação. A maneira como

os neurônios estão estruturados está, intrinsecamente, relacionada ao algoritmo de aprendizagem que será utilizado para treinar a rede. Nesse sentido, há duas classes de arquiteturas de rede (a forma como os neurônios estão dispostos): a) redes alimentadas adiante com camada única, isto é, uma camada formada pelos neurônios de entrada se projeta sobre uma camada de saída, mas não vice-versa; b) redes alimentadas diretamente com múltiplas camadas, redes competitivas ou recorrentes, na qual a camada de entrada projeta-se sobre a camada de saída (ou camadas intermediárias) e vice-versa.

Para Fausett (1994), as Redes Neurais Artificiais (RNA) são modelos matemáticos com diversos parâmetros de treinamento, os quais são modificados de acordo com um conjunto de dados que contém informações sobre o comportamento que esta rede deve apresentar.

A partir de conceitos importantes enunciados por Haykin (2001), uma RNA extrai seu poder computacional por meio de sua estrutura maciçamente e paralelamente distribuída e, ainda, por sua habilidade de aprendizado, ou seja, seu poder de generalização o que tem haver com a capacidade que a rede terá de produzir saídas adequadas para entradas que não estão presentes durante a aprendizagem ou treinamento da mesma. Tais habilidades tornam redes neurais capazes de resolver problemas complexos que seriam manualmente impossíveis de serem tratados.

Dentro de um mesmo raciocínio de análise, já discutidas e detalhadas por Haykin (2001), os autores Alvarez e Luque (2003), também definem RNA como técnicas computacionais que apresentam um modelo matemático inspirado na estrutura neural de organismos inteligentes e que adquirem conhecimento através da experiência. Os neurônios se comunicam através de sinapses. Os autores ainda afirmam que uma rede neural artificial é composta por várias unidades de processamento, cujo funcionamento é bastante simples. Essas unidades, geralmente são conectadas por canais de comunicação que estão associados a determinado peso e fazem operações apenas sobre seus dados locais, que são entradas recebidas pelas suas conexões. O comportamento inteligente de uma Rede Neural Artificial vem das interações entre as unidades de processamento da rede.

Uma rede neural precisa de uma regra de treinamento, onde os pesos de suas conexões são ajustados de acordo com os padrões apresentados. Em outras palavras, uma RNA aprende por meio de exemplos. As estruturas neurais são, geralmente, dispostas em camadas. Estas, comumente, são divididas em três grupos: a) camada de entrada, na qual os padrões são

fornecidos à rede; b) camadas intermediárias, nas quais acontece todo o processamento dos dados e a extração das características e; c) camada de saída, na qual acontece a apresentação do resultado final resultante do processamento dos dados (ALVAREZ e LUQUE, 2003).

Outra questão importante refere-se ao modo pelo qual a rede neural será treinada. Os autores citados anteriormente diferenciam dois modelos padrões: o aprendizado supervisionado e o aprendizado não supervisionado. No primeiro, a RNA é treinada com ajuda de um supervisor; a rede deve possuir um conjunto de entradas e um conjunto de saídas necessárias a cada entrada. A interação do treinamento será repetida com todo o conjunto treinado (entradas e saídas), até que se atinja um percentual de acerto considerado satisfatório. No segundo modelo, não haverá um indicador externo para indicar a resposta desejada aos padrões de entrada, logo, é um aprendizado auto supervisionado ou auto-organizado uma vez que não terá saída desejada. Isso significa que não haverá um supervisor para realizar o treinamento.

Silva (2003) discute sobre os tipos de algoritmos utilizados para promover o aprendizado de redes neurais. Para os algoritmos com aprendizado supervisionado, um conjunto de saídas desejadas é fornecido por um supervisor externo e a rede tem que mapear as entradas fornecidas nas saídas desejadas.

Conforme Silva (2003), um algoritmo com aprendizado não-supervisionado ou também dito auto-organizável terá que identificar padrões ou características significativas nos dados de entrada sem o auxílio de um supervisor externo. Nesse sentido, o autor afirma, também, que os sistemas auto-organizáveis podem apresentar diferentes formatos e tendem a assemelhar-se a estruturas neurobiológicas.

Conforme o autor citado anteriormente há alguns princípios básicos e intuitivos de auto-organização. Dentre eles: as modificações nos pesos sinápticos tendem a se auto amplificarem a partir de sinais locais (pré e pós-sinápticos); a restrição de recursos promove disputa entre sinapses e, com isso, haverá seleção das sinapses mais fortes em relação às outras; e ainda, as mudanças nos pesos sinápticos propiciam a cooperação, ou seja, uma sinapse (região de comunicação entre dois neurônios) mais forte pode aumentar a aptidão de outras em relação a todo o conjunto da rede neural. Contudo, vale ressaltar que toda essa dinâmica de operacionalidade refere-se, especificamente, a uma rede na qual o algoritmo utilizado adota um padrão não supervisionado.

Conforme explica Becker (1991), em um processo de aprendizagem não supervisionado ou auto organizado, a rede deve ajustar-se às regularidades estatísticas dos dados de entrada e desenvolver habilidades de formar representações internas, para codificar as características da entrada e, desse modo, criar automaticamente novas classes. Já no aprendizado supervisionado, um analista externo informa à rede uma resposta desejada para um determinado vetor de treinamento, ou seja, a resposta desejada representa a ação ótima a ser realizada pela RNA.

No contexto de redes neurais artificiais, a aprendizagem é definida como:

Processo pelo qual os parâmetros livres de uma RNA são adaptados por meio de um processo de estimulação pelo ambiente no qual a rede está inserida. O tipo de aprendizagem é determinado pelo modo no qual a modificação dos parâmetros ocorre (MENDEL e MACCLAREN, 1970, p.287).

A definição do processo de aprendizagem está relacionada a três eventos sequenciais:

- 1) A RNA é estimulada por um ambiente.
- 2) A RNA sofre modificações em seus parâmetros livres como resultado da estimulação.
- 3) A RNA responde de maneira nova ao ambiente, devido às modificações acontecidas em sua estrutura interna (HAYKIN, 2001, p.76).


Haykin (2001), explica também que, a base de uma rede neural configura-se a partir de seus neurônios artificiais que são unidades de processamento de informação. A maneira como os neurônios estão estruturados está, intrinsecamente, relacionada ao algoritmo de aprendizagem que será utilizado para treinar a rede. Nesse sentido, há duas classes de arquiteturas de rede (a forma como os neurônios estão dispostos): a) redes alimentadas adiante com camada única, isto é, uma camada formada pelos neurônios de entrada se projeta sobre uma camada de saída, mas não vice-versa; b) redes alimentadas diretamente com múltiplas camadas, redes competitivas ou recorrentes, na qual a camada de entrada projeta-se sobre a camada de saída (ou camadas intermediárias) e vice-versa.

É importante dizer que as unidades de processamento, quando agrupadas através de canais de comunicação com determinado peso, compõem a rede neural artificial, mas a inteligência da rede provém das interações destas unidades de processamento (CHANCHETTI, 2010).

Historicamente, um modelo tradicional de RNA foi proposto por McCulloch e Pitts (1943) - modelo estocástico de um neurônio (Figura 3). Segundo Chanchetti (2010), tal modelo pode ser resumido da seguinte forma:

- 1° Sinais são apresentados à entrada;
- 2° Cada sinal é multiplicado por um número, ou peso, que indica a sua influência na saída da unidade;
- 3° É feita a soma ponderada dos sinais que produz um nível de atividade;
- 4° Se este nível de atividade exceder certo limite (*threshold*) a unidade produz uma determinada resposta de saída.

Figura 3. Esquema de unidade McCulloch - Pitts.



Fonte: McCULLOCK (1943).

Se há p (valores numéricos) sinais de entrada X_1, X_2, \dots, X_p e pesos W_1, W_2, \dots, W_p e limitador t , com sinais assumindo valores booleanos (0 ou 1) e pesos valores reais.

Neste modelo, o nível de atividade a (valor numérico) é dado pela equação (3.1):

$$a = W_1X_1 + W_2X_2 + \dots + W_pX_p \quad (3.1)$$

a saída y é dada por:

$$y = 1, \text{ se } a \geq t \text{ ou} \\ y = 0, \text{ se } a < t.$$

Logo, é possível inferir que, a maioria dos modelos de redes neurais possui alguma regra de treinamento, onde os pesos de suas conexões são ajustados de acordo com os padrões apresentados, ou seja, a rede neural aprende por meio de exemplos.

A partir da introdução do conceito de RNA, por McCulloch e Pitts (1943), no artigo *A logical calculus of the ideas immanent in nervous activity*, enquanto máquinas computacionais (HAYKIN, 2001, p143), em 1958, Rosenblatt propõe o modelo perceptron


como o primeiro protótipo para aprendizagem com um professor (aprendizagem supervisionada)(HAYKIN, 2001, p144). Conforme Haykin (2001), o perceptron é a forma mais simples de uma RNA utilizada para a classificação de padrões ditos linearmente separáveis, ou seja, padrões que se encontram em lados opostos de um hiperplano. Tal modelo pode ser subdividido, basicamente, em dois parâmetros: perceptrons de camada única e perceptrons de múltiplas camadas. A seguir uma distinção sintética sobre os dois modelos.

O perceptron construído em torno de um único neurônio com pesos ajustáveis é limitado a realizar classificação de padrões com apenas duas classes (hipóteses). Rosenblatt provou que os padrões (vetores) usados para treinar o perceptron são retirados de duas classes linearmente separáveis, logo, o algoritmo do perceptron converge e posiciona a superfície de decisão na forma de um hiperplano entre as duas classes. A prova de convergência do algoritmo é conhecida como teorema de convergência do perceptron (HAYKIN, 2001).

Já em um perceptron de múltiplas camadas, a rede compreende um conjunto de unidades sensoriais (nós de fonte) que consistem em uma camada de entrada, uma ou mais camadas ocultas de nós computacionais e, por último, uma camada de saída de nós computacionais. Essas RNA são usualmente denominadas perceptrons de múltiplas camadas (MLP, Multi Layer Perceptron) (HAYKIN, 2001).

A Figura 4 mostra a topologia de uma RNA do tipo MLP (HAYKIN, 2001).

Figura 4. Topologia de uma RNA : MLP - Multi Layer Perceptron (3 camadas: uma camada de entrada com 4 neurônios, uma camada oculta com 3 neurônios e uma camada de saída com 2 neurônios).



Fonte: <http://cerebroken.blogspot.com.br/2011/08/redes-neurais-artificiais.html>. Acesso: 13 out. 2012.

De acordo com Chanchetti (2010), uma RNA do tipo MLP possui camadas com três grupos:

a) **Camada de Entrada:** onde os padrões são apresentados à rede;

b) **Camadas Intermediárias ou Ocultas:** onde é feita a maior parte do processamento, através das conexões ponderadas; podem ser consideradas como extratoras de características;

c) **Camada de Saída:** onde o resultado final é concluído e apresentado.

Em síntese, uma rede neural é especificada, principalmente, pela sua topologia, pelas características dos nós e pelas regras de treinamento (CHANCHETTI, 2010).

3.2.2.2 Self-Organizing Feature Maps (SOFM)

Segundo Haykin (2001), há inúmeros modelos rede de aprendizagem, na qual um dos modelos mais conhecidos e utilizados denomina-se SOM (Self-Organizing Map), muito usada para agrupamento de padrões, otimização de problemas e simulações, capturando as características importantes contidas em espaço de entrada multidimensional.

De acordo com Kohonen (2001), é estabelecido um modelo de rede neural, denominada competitiva, a de interesse na pesquisa realizada. A aprendizagem competitiva caracteriza-se por ser um processo adaptativo no qual os neurônios, numa rede neural artificial, tornam-se gradualmente sensíveis a diferentes categorias de entrada e a conjuntos de amostras em um domínio específico do espaço de entrada. O mapa auto-organizável de Kohonen é uma RNA com duas camadas (Figura 5).

Nesse sentido, percebe-se que, em uma rede de Kohonen o neurônio com a maior resposta para uma determinada entrada terá os pesos de suas sinapses preparados para aumentar sua resposta mediante ao padrão de entrada. Isso caracterizará o treinamento competitivo da rede. A dimensão de saída pode ser uni ou n-dimensional (geralmente bidimensional). Vale lembrar que o aprendizado da rede neural dependerá, diretamente, dos parâmetros adotados, como: razão de aprendizagem, tipo de vizinhança, dentre outros. O modelo de Kohonen possui um padrão mais geral por permitir um mapeamento entre conjuntos de dimensões diferentes (BOTTER et al., 2005).

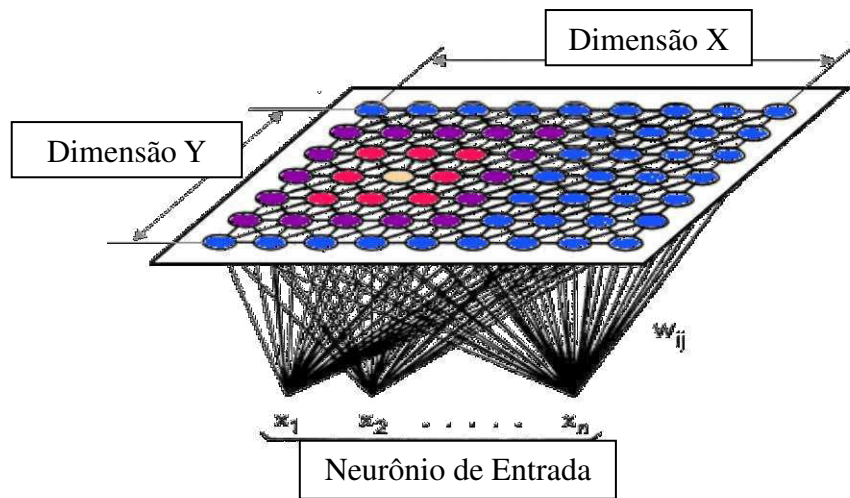
O modelo de Kohonen para uma RNA foi criado em 1981, pelo engenheiro Teuvo Kohonen, da Universidade de Helsinque. Ele procurou estabelecer uma relação direta entre o comportamento do cérebro humano e seu modelo, de maneira que este pudesse ser utilizado para auto-organizar padrões similares. Esta tentativa partiu do princípio de que o cérebro humano é capaz de executar tarefas complexas, tal como o reconhecimento de padrões, em frações de segundo. Assim, os Mapas de Kohonen são baseados na forma como o cérebro armazena as informações (KOHONEN, 2001).

A rede de Kohonen corresponde a um reticulado, em forma de rede com linhas e nervuras entrecortadas, n-dimensional, de neurônios de saída, conectado às entradas, munido de uma topologia que garante a existência de vizinhos para um determinado neurônio (Figura 5). Esse conjunto, depois de treinado, representará uma função discriminante dos sinais n-dimensionais de entrada. O neurônio com maior resposta a uma determinada entrada tem os pesos de suas sinapses atualizados, caracterizando um treinamento competitivo da rede, tendo os pesos dos neurônios vizinhos do vencedor também atualizados. Esse processo garante a topologia e funcionamento da rede (BOTTER et al., 2005).

Os SOFM são conhecidos como um sistema de aprendizado competitivo não supervisionado que consegue extrair características a partir de um conjunto de dados de treinamento. A partir de uma camada bidimensional de neurônios, representada por um conjunto de pesos iniciais, o algoritmo de treinamento do SOFM realiza uma auto-organização destes neurônios de forma que os mesmos passem a representar características do conjunto de treinamento utilizadas (KOHONEN e MÄKISARA, 1989; KOHONEN 1982, 1988, 1990).

As leis de aprendizado do tipo competitivas têm como propriedade comum um processo de concorrência que envolve alguns ou todos os neurônios da RNA que sempre acontece antes de cada episódio de aprendizado. Os neurônios considerados vencedores no processo competitivo têm seus pesos atualizados de uma forma diferenciada dos demais neurônios considerados não vencedores (KOHONEN, 2001). Conclusivamente, O SOFM consiste de duas camadas, uma camada unidimensional de entrada e uma camada de grade bidimensional com um número arbitrário de unidades (KOHONEN, 1990). Cada unidade de camada de entrada é conectada com todas as unidades na camada de saída (Figura 5).

Figura 5. Estrutura de uma RNA de Kohonen.



Fonte: Adaptado de LOURENÇO (2010).

4 MATERIAIS E MÉTODOS

4.1 Área de estudo

A área de estudo escolhida foi o Estado de Goiás e seus municípios (Figura 6). Os dados utilizados referem-se à produção canavieira relativa à área de plantio, em hectares; o quantitativo do rebanho bovino, em número de cabeças e a produção leiteira do rebanho bovino, em litros. A pesquisa engloba informações disponíveis relacionadas aos 246 municípios da Unidade Federativa (Goiás). Os dados de produção a serem utilizados já contemplam, no caso da cana-de-açúcar, a área total plantada em hectares o que inclui a época de plantio e replantio da cultura.

Figura 6. Localização Geográfica do Estado de Goiás.



Fonte: Autor (2013).

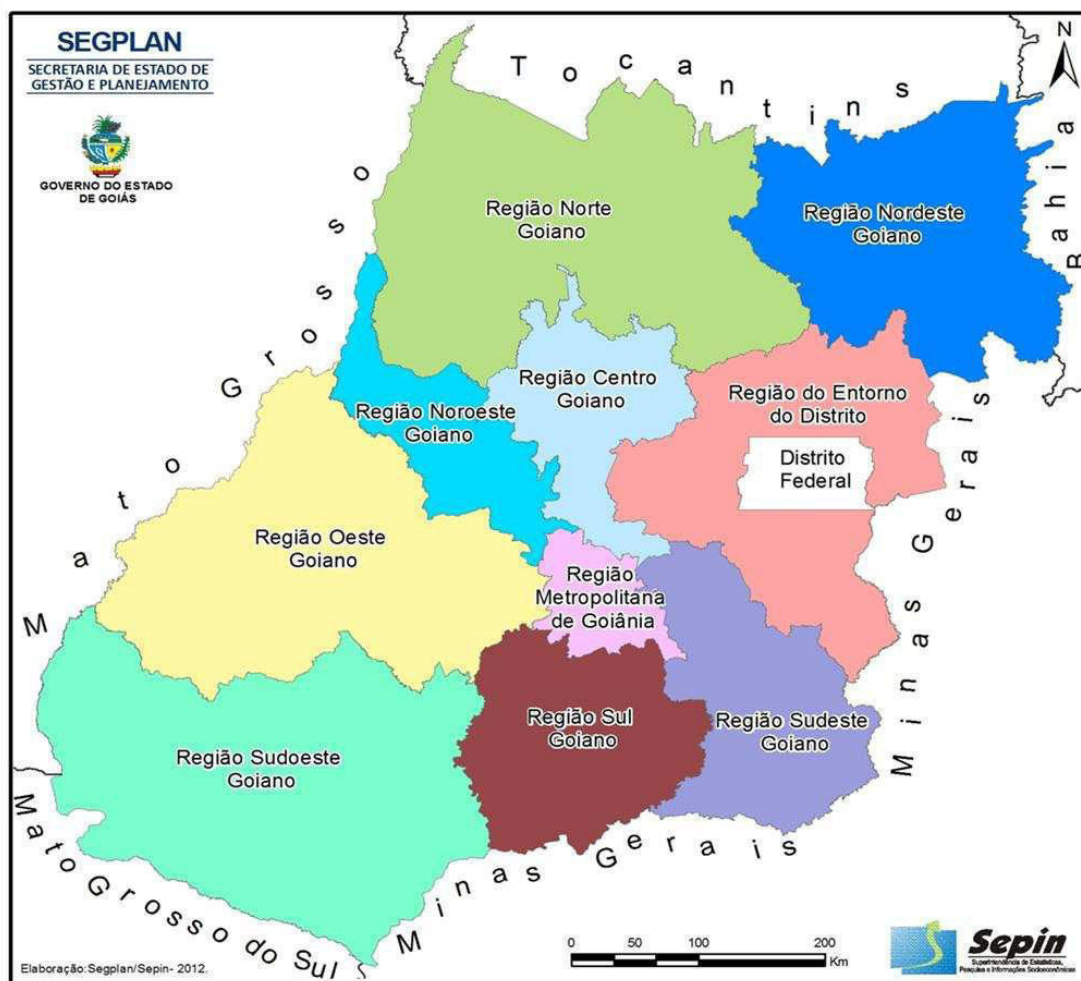
Localizado no eixo central brasileiro e ocupando cerca de 3,99% do território, Goiás possui clima predominantemente tropical, com a divisão marcante de duas estações bem definidas durante o ano: verão úmido, nos meses de dezembro a março e inverno seco, predominante no período de junho a agosto; situa-se sobre o Planalto Central Brasileiro e

abriga em suas terras um mosaico de formações rochosas distintas quanto à idade e à composição (GOIÁS, 2012).

Está localizado na região Centro-Oeste e ocupa uma área de 340.086 km² e limita-se ao Norte com o Estado do Tocantins, ao Sul com Minas Gerais e Mato Grosso do Sul, a leste com Bahia e Minas Gerais e a Oeste com Mato Grosso; ocupa a sétima posição em extensão territorial, abrigando em seus domínios 246 municípios delimitados (Figura 6) e uma população de mais de seis milhões de habitantes, conforme o Censo Demográfico do IBGE de 2010 (GOIÁS, 2012).

O Estado de Goiás está subdividido em dez (10) regiões de planejamento, a saber: Norte, Nordeste, Noroeste, Centro-Oeste, Entorno do Distrito Federal, Oeste, Metropolitana de Goiânia, Sudoeste, Sul e Sudeste Goianos (Figura 7). Cada uma das regiões possui microrregiões o que totaliza os 246 municípios que integram a Unidade Federativa de Goiás (SEPLAN/SEPIN, 2005). A Figura 7 demonstra as regiões de planejamento e a quadro (1) abaixo indica o quantitativo municipal relacionado a cada uma delas.

Figura 7. Estado de Goiás e Regiões de Planejamento.



Fonte: SEPLAN/IMB (2012).

Quadro 1: Regiões de planejamento de Goiás e o quantitativo de municípios.

	Regiões de Planejamento	Número de Municípios
	Centro Goiano	31
	Entorno do Distrito Federal	19
	Metropolitana de Goiânia	20
	Nordeste Goiano	20
	Noroeste Goiano	13
	Norte Goiano	26
	Oeste Goiano	43
	Sudeste Goiano	22
	Sudoeste Goiano	26
	Sul Goiano	26
	TOTAL DE MUNICÍPIOS	246

Fonte: SEPLAN (2012).

Nesse contexto, a produção canavieira brasileira concentra em sua maior parte na região centro sul onde predomina o cerrado. Isso acontece também com outras culturas. Pode-se destacar ainda a pecuária de corte e leiteira que ocupa imensas extensões territoriais nas quais o cerrado nativo foi substituído por área de pastagem ou por lavouras. Isso degrada o bioma local e vem dificultando a sua proteção legal pela ação do poder público. Ainda, grande parte da pecuária brasileira encontra-se no Cerrado; a região centro-oeste na qual o cerrado é característico contribui com 30% dessa atividade; esta produção concentra-se principalmente em Mato Grosso, Mato Grosso do Sul e Goiás (MMA, 2009).

Dentre as culturas agrícolas produzidas no Brasil, a cana-de-açúcar ocupa o terceiro lugar em relação à área plantada com 8,43 mil hectares, sendo Goiás responsável por 8,1% (678,42 mil hectares) desse total para a safra 2009/2010. Logo, o Brasil é o maior produtor mundial de cana-de-açúcar (CONAB, 2011).

Os dados do Ministério do Meio Ambiente são relevantes:

Ao contrário do que ocorreu no passado, quando as iniciativas eram governamentais, hoje o setor privado corre para ampliar suas unidades, na certeza de que o álcool terá um papel cada vez mais importante como combustível. O Primeiro relatório da conab sobre estimativas da Produção da Cana-de-açúcar (CONAB, 2009) para o período 2009/2010, indicam um aumento de 10,1% a 12,3% no volume da cana a ser processada para a região Centro Sul (Sudeste, Sul e Centro-Oeste), cuja participação está próxima de 90% do total nacional. Desse total, foi estimado que 44,7% serão destinados à fabricação de açúcar e 55,3% à produção de álcool, em relação ao ponto médio. O desempenho dos estados revela que na Região Centro-Sul, o crescimento da produção ocorre em praticamente todos os estados, com destaque para Goiás com acréscimo de 47,3%, Mato Grosso do Sul (28,7%), Paraná (20,2%) e Minas Gerais (14,9%) (MMA, 2009, p. 48).

Dentre os estados que concentra o bioma o Cerrado, os maiores produtores de cana-de-açúcar em ordem decrescente são: São Paulo, Minas Gerais, Goiás e Paraná. De acordo com a CONAB, São Paulo é o primeiro, com 5.533 mil hectares cultivados, o segundo é Minas Gerais com 908,28 mil hectares cultivados, o terceiro colocado é o Estado de Goiás, sua produção é de 847,359 mil hectares de área cultivada. Diante desse cenário, é possível perceber que a maior produção de cana-de-açúcar se concentra nos Estados que apresenta mais de 33% de área do bioma Cerrado, o que corresponde a 82,46% da produção nacional (CONAB, 2011).

4.1.1 A produção sucroalcooleira no Brasil e em Goiás

Conforme dados da União da Indústria de cana-de-açúcar (UNICA), toda a expansão da cultura canavieira corrobora com a crescente propagação de polos industriais para fabricação de álcool e açúcar no Brasil, totalizando 386 usinas (Quadro 2) em funcionamento apenas nos estados de São Paulo, Minas Gerais, Goiás, Mato Grosso e Mato Grosso do Sul; sendo que o total nacional é de 554. A expectativa é de que várias novas usinas entrem em operação na região Centro-Sul, como é o caso dos estados mencionados com 120 novas usinas das 134 esperadas para o Brasil (UNICA, 2012).

Quadro 2: Usinas produtoras de álcool e açúcar nos 5 maiores estados produtores

Estado Produtor	Total de Unidades Produtoras
São Paulo	209
Minas Gerais	67
Mato Grosso do Sul	22
Goiás	73
Mato Grosso	15
TOTAL	386

Fonte: União da indústria de cana-de-açúcar – UNICA (2012).

Diante desse cenário, é perceptível que a estrutura do setor sucroalcooleiro em Goiás encontra-se em expansão vertiginosa. A área colhida no mesmo período cresceu 315,7%, o que significa o 3º lugar no ranking nacional, para a área plantada. O expressivo aumento na produção é resultado da instalação de dezenas de usinas do setor sucroenergético, atendendo ao crescimento da demanda pelos derivados do produto, como etanol e açúcar. Nas últimas décadas, a expansão da cana-de-açúcar, nos municípios goianos, é o reflexo de novos projetos industriais do setor, com o objetivo de suprir a demanda de outros países e abastecer o mercado interno, principalmente atendendo à necessidade mundial de geração de energia limpa. Tal situação favorece a ocorrência de um fenômeno importante que se caracteriza pela substituição de culturas tradicionais em alguns municípios, devido à instalação de novas usinas, como é o caso de Itumbiara, Paraúna, Goiatuba e Acreúna (SEPLAN, 2011).

Um raciocínio similar para a pecuária goiana, conforme informações oficiais do governo do Estado de Goiás e das principais entidades de classe de produtores rurais mostram

a possibilidade de avanço da cultura sobre as áreas de pastagens degradadas e pela diminuição da quantidade de pasto com a aplicação de novas tecnologias ligadas a criação bovina. Entretanto, ao que parece, o movimento de expansão da cultura canavieira, por enquanto, tem sido feito, prioritariamente, nas áreas de culturas agrícolas. De acordo com Santos (2009), no período de 2003/2008, do total da área de expansão canavieira nos cerrados 60% aconteceram sobre a área da produção agrícola, 33% sobre as áreas de pecuárias e 4% sobre as áreas com vegetação nativa.

Conforme afirma Baccarin et al.,(2010), em Goiás com a expansão da cultura da cana-de-açúcar cresceu também a cultura de outras lavouras e ocorreu redução das áreas de pastagens. No mesmo estudo, fica claro que, conforme dados do censo agropecuário 1995/96 e 2005/2006, não ocorreram competição por área entre lavouras até então. O fato concreto é que não há possibilidade de reversão ou diminuição da ocupação das áreas agrícolas tradicionais produtoras de grãos pela cana-de-açúcar em Goiás. Nesse sentido, percebe-se que a diminuição das atividades produtivas, especificamente de grãos em Goiás, poderá impactar fortemente nos sistemas agroindustriais de carnes do Estado, motivo pelo qual a ordenação do espaço produtivo precisa embasar-se em uma política agrícola de longo prazo de organização produtiva, nas esferas municipais, estaduais e federais, de modo a permitir que a expansão da cultura de cana-de-açúcar que, na atualidade, parece soar como um “boom” econômico pujante não venha a se tornar uma catástrofe na economia dos municípios goianos.

4.1.2 Os indicadores de produtividade do Estado de Goiás relacionados ao setor sucroalcooleiro (produção de cana-de-açúcar), pecuária de corte bovina e pecuária leiteira

A cana-de-açúcar está distribuída por 193 municípios goianos que estão distribuídos nas cinco Mesorregiões Geográficas definidas pelo IBGE. Ao analisar as mesorregiões (ver seção 4.1), fica evidente a concentração em duas: a do Sul Goiano que, em 2010, concentrava 77,4% da produção e a mesorregião do Centro Goiano que respondeu por 17,9%. As duas mesorregiões representaram 95,3% da produção estadual. No recorte municipal, os maiores produtores naquele ano foram: Quirinópolis (7,7%), Santa Helena de Goiás (6,7%), Porteirão (4,6%) e Mineiros (4,2%). As particularidades produtivas desta cultura favoreceram sua concentração em municípios goianos que têm especificidades, contemplando uma alta produção concentrada em 24 (vinte e quatro) municípios goianos (Quadro 3) (IBGE, 2012).

Quadro 3: Municípios Goianos com alta produção de cana-de-açúcar (área plantada em hectares)

Município	Área Plantada (ha)
Acreúna	16.785
Anicuns	12.100
Bom Jesus de Goiás	29.200
Chapadão do Céu	22.535
Edéia	15.860
Goianésia	14.500
Goiatuba	23.370
Gouvelândia	19.200
Inaciolândia	14.600
Itapuranga	10.612
Itumbiara	26.600
Jandaia	11.452
Jataí	18.000
Itumbiara	26.600
Maurilândia	13.130
Mineiros	21.101
Morrinhos	18.000
Nova Glória	12.893
Paranaiguara	10.470
Porteirão	27.700
Quirinópolis	48.000
Rio Verde	14.300
Santa Helena de Goiás	30.090
Turvelândia	17.160
Vila Propício	22.490

Fonte: IBGE. Elaboração: SEGPLAN-GO/IMB/GSDIS – 2012.

A partir das informações coletadas e analisadas percebe-se que, dentre os 246 municípios goianos, apenas 24 deles possuem perfil de alta produtividade, ou seja, aqueles em que a área de plantio da cana-de-açúcar é superior a 10.000 hectares (ha). Diante dessa realidade, constata-se em percentuais estatísticos que apenas 9,8% dos municípios fazem parte

do grupo com alta produtividade e 90,2% com produção baixa, isto é, com área de plantio inferior a 10.000 hectares (ha). Conforme os resultados apresentados na seção 5.2, que explicita a sinclassificação temporal aplicada à produção de cana-de-açúcar, pecuária bovina de corte e leiteira em Goiás, é possível afirmar, com segurança, que o processo de classificação temporal realizado pela rede SOFM proposta é válido, preciso e demonstra a realidade do perfil produtivo dos municípios goianos, em relação à produtividade de cana-de-açúcar no Estado de Goiás.

Quanto ao perfil produtivo que envolve a pecuária bovina de corte, os indicadores oficiais, também, refletem o comportamento eficiente da rede SOFM no processo de classificação temporal. O rebanho de corte bovino goiano em 2011 somou 21,744 milhões de cabeças, com aumento de 1,86%, ou seja, 396.769 animais a mais que em 2010. Em escala municipal, Nova Crixás é o maior produtor goiano e o 10º no ranking nacional, com 710 mil cabeças, seguido por São Miguel do Araguaia, com 572 mil cabeças, e na 26ª posição nacional. O quadro 5 demonstra os municípios com alta produtividade relativa ao rebanho de corte bovino (SEPLAN, 2012).

Quadro 4: Municípios Goianos com alta produção do rebanho bovino de corte/ano 2010 (número de cabeças).

Município	Número de cabeças
Araguapaz	185.400
Aruanã	266.935
Bela Vista de Goiás	128.120
Caiapônia	407.200
Catalão	173.000
Corumbaíba	154.500
Cristalina	150.400
Flores de Goiás	133.827
Formosa	228.010
Goianésia	110.000
Goiás	257.730
Iaciara	134.000
Ipameri	195.000
Itumbiara	164.200

Jaraguá	158.250
Jataí	321.370
Jussara	394.569
Luziânia	172.000
Montes Claros de Goiás	290.500
Morrinhos	295.000
Nova Crixás	744.960
Piracanjuba	215.000
Porangatu	340000
Quirinópolis	330.000
Rio Verde	400.000
São Domingos	139.000
São Miguel do Araguaia	570000

Fonte: IBGE. Elaboração: SEGPLAN-GO/IMB/GSDIS – 2012.

Diante das informações disponibilizadas percebe-se que, dentre os 246 municípios goianos, apenas 27 deles possuem alta produtividade, ou seja, aqueles em que o número de cabeças do rebanho bovino é superior a 100.000 cabeças (Quadro 4). Para essa variável de produção, constata-se em percentuais estatísticos que aproximadamente 11% dos municípios fazem parte do grupo com alta produtividade e 89% com produção baixa produção, isto é, com número de cabeças bovinas inferiores a 100.000 cabeças.

Em relação à produção leiteira bovina, os indicadores oficiais demonstram que a classificação temporal realizada pela rede SOFM foi correta e precisa. Em Goiás, no ano de 2011, a produção de leite chegou a 3,482 bilhões de litros, um acréscimo de 9% sobre o ano anterior. Foram ordenhadas 2,615 milhões de vacas em todo o Estado, representando 12% do efetivo total de bovinos. Dos cinco maiores municípios brasileiros produtores de leite, dois são goianos: Jataí, 3ª posição no ranking nacional com 141,4 milhões de litros, seguido do município de Morrinhos, em 4º lugar, com 128,8 milhões de litros de leite. O Quadro 5, demonstra os municípios com alta produção leiteira (SEPLAN, 2012).

Quadro 5: Municípios Goianos com alta produção de leite/ano 2010 (mil litros).

Município	Quantidade de litros
Anicuns	38.400
Bela Vista de Goiás	31.330
Catalão	79.380
Crixás	20.700
Goiás	27.636
Inhumas	31.450
Ipameri	62.370
Itaberaí	27.000
Itapuranga	27.060
Itumbiara	37.600
Jaraguá	28.000
Jataí	119.256
Jussara	25.284
Luziânia	68.590
Mineiros	58.964
Morrinhos	112.007
Niquelândia	27.000
Orizona	75.000
Paraúna	24.669
Piracanjuba	114.313
Pirenópolis	32.000
Rio Verde	78.800
São Miguel do Araguaia	29.000
Trindade	50.010

Fonte: IBGE. Elaboração: SEGPLAN/IMB/GSDIS – 2012.

A partir das informações coletadas e analisadas percebe-se que, dentre os 246 municípios goianos, apenas 24 deles possuem alta produtividade, ou seja, aqueles em que a produção leiteira foi superior a 20.000 litros. Para essa variável de produção, constata-se em percentuais estatísticos que aproximadamente, 10% dos municípios fazem parte do grupo com alta produtividade e 90% com baixa produção, ou seja, inferior a 20.000 litros produzidos por

ano. Portanto, o perfil produtivo dos municípios goianos para os indicadores de produção da cana-de-açúcar, pecuária de corte e leite mostram que há um quantitativo grande de municípios com baixa produção e pequena quantidade de grandes produtores (SEPLAN, 2012).

Esse comportamento pode ser representado por meio de gráficos denominados histogramas. O histograma mostra a representação de dados quantitativos agrupados em classes de frequência que permite distinguir a forma, o ponto central e a variação da distribuição, amplitude e simetria dos dados (WADSWORTH, 1986, p.300). Pode-se exemplificar a área plantada de cana-de-açúcar (em ha)(Gráfico 1) referente aos anos de 1995 e 2010. No eixo horizontal (x) estão indicados os intervalos do quantitativo da produção e, no eixo vertical (y) estão representadas as frequências (quantidade de municípios). O comportamento foi similar para a pecuária bovina de corte e leite.

Gráfico 1: Frequência de distribuição da produção de cana-de-açúcar (em ha).



Fonte: Autor (2013).

É notório que há uma grande quantidade de pequenos produtores (pico próximo de zero em relação ao eixo horizontal (x)) e poucos municípios com alta produção. Mais precisamente, conforme dados oficiais (IBGE, 2012), cerca de apenas 10% dos municípios goianos são considerados grandes produtores (produção superior a 10.000 hectares de área plantada para a cana-de-açúcar)

4.2. Etapas da pesquisa

Para o desenvolvimento da pesquisa estabeleceu-se três etapas que serão descritas a seguir:

1ª Etapa: a coleta dos dados compreendeu a primeira etapa. Os dados coletados (atributos de produção de cana-de-açúcar, rebanho bovino e produção leiteira) referentes aos 246 municípios do Estado de Goiás foram disponibilizados a partir do Banco de Dados Agregados – Sistema IBGE de Recuperação Automática (SIDRA). As informações foram acessadas e retiradas do site (<http://www.sidra.ibge.gov.br/>). Os dados referentes à área de plantio da cultura de cana-de-açúcar (em hectares), o quantitativo do rebanho bovino goiano (em número de cabeças) e a quantidade de leite produzido no Estado (em litros), adquiridos para o desenvolvimento deste trabalho referem-se aos anos de 1995 e 2010 (anexos 1, 2 e 3);

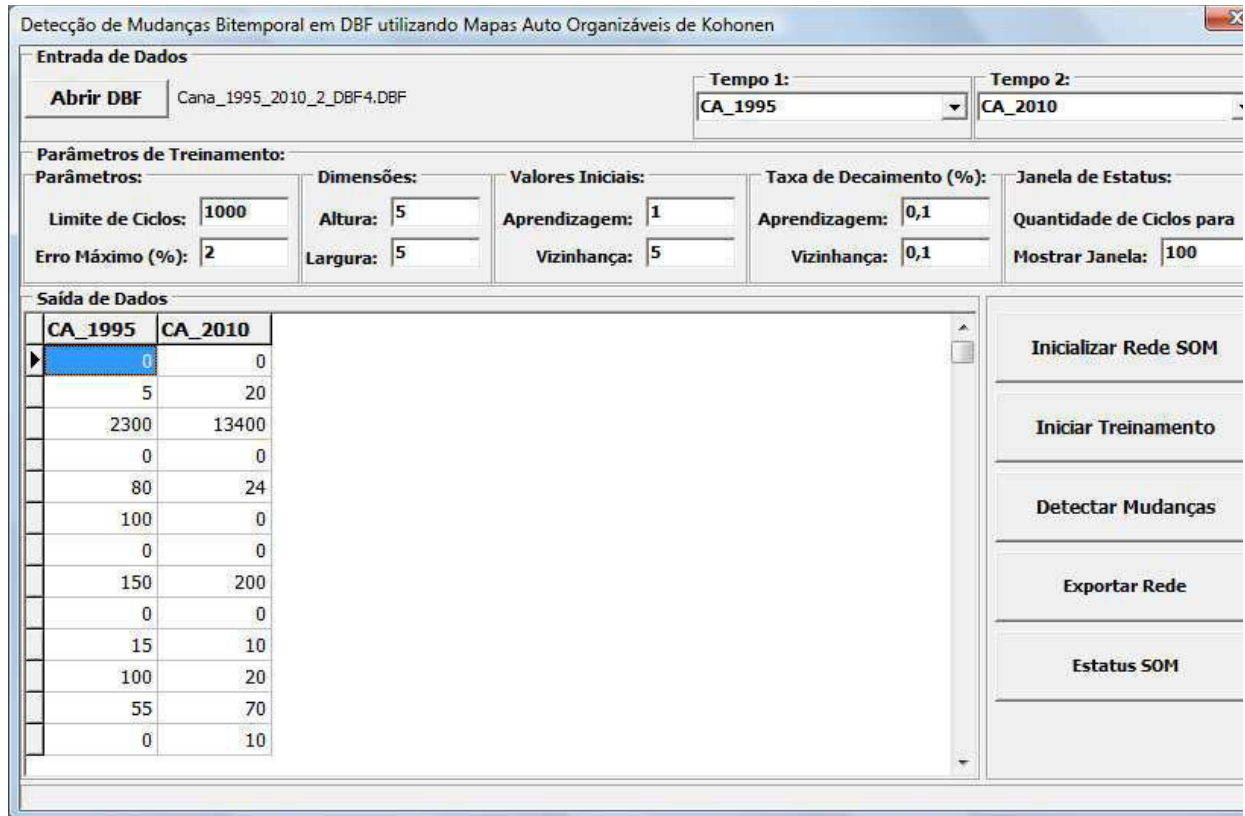
2ª Etapa: para a realizar o estudo de detecção de mudanças da produção agropecuária em Goiás, utilizou-se os softwares: **SOFM: Detecção de Mudanças (DBF – 2 tempos)**, **MATLAB 7.10.0 R2010a (MATrix LABoratory)** e **ArcGis 10.1**, que serão referenciados a seguir. A partir da detecção de mudanças aplicada aos dados coletados do Sistema SIDRA/IBGE será possível avaliar os perfis de variações produtivas relacionadas à cana-de-açúcar, pecuária bovina de corte e leiteira dos municípios do Estado de Goiás referente aos anos de 1995 e 2010. O emprego desta técnica utilizando dados do setor agropecuário permitirá a caracterização dos municípios goianos em relação ao seu comportamento produtivo temporal.

3ª Etapa: Finalmente, foram utilizadas as análises estatísticas resultantes do processo de detecção de mudança temporal, para avaliar a acurácia das classificações realizadas e espera-se ser possível descrever, com detalhes, as características dos agrupamentos encontrados.

4.3 – Interface e descrição dos softwares utilizados na pesquisa

4.3.1 – DMB - SOFM: Detecção de Mudanças Bitemporal:


Figura 8. DMB - SOFM: RNA utilizada no processo de detecção de mudanças referente às variações produtivas utilizadas na pesquisa.



Fonte: Protótipo desenvolvido para a pesquisa adaptado de SILVA (2003).

Uma rede auto-organizável (SOFM) assemelha-se aos conceitos de auto-organização cerebral. O cérebro é um sistema organizado que aprende espontaneamente, sem a necessidade de um professor. Tal rede também pode ser denominada de memória associativa por competição ou Rede de Kohonen. Ela é constituída por duas camadas (uma de entrada e uma competitiva), como mostrado na Figura 9. Cada neurônio da camada de entrada vai estabelecer uma dimensão do padrão de entrada e distribuir esse componente para a camada competitiva. Com o atual conhecimento sobre as redes de Kohonen, acredita-se mais na regra de aprendizado de Hebb, onde se percebe que quando um neurônio A, de forma contínua, ajuda a disparar um neurônio B, a eficácia da associação entre esses dois neurônios vai aumentar progressivamente (HEBB, 1949).

Figura 9. Exemplo da topologia de uma rede de Kohonen. Os neurônios da camada de entrada estão ligados a todos os neurônios da camada de saída (competitiva) através de pesos. Já os neurônios da camada de saída estão ligados a alguns neurônios da mesma camada, e estes constituem a sua vizinhança.



Fonte: Adaptado de LIPPMANN (1987).

Um mapa auto-organizável, conforme explica (LIPPMANN, 1987) é treinado utilizando uma aprendizagem híbrida composta por aprendizagem Hebbiana (Baseada no postulado de aprendizagem de Hebb (HEBB, 1949), que diz: “se dois neurônios em ambos os lados de uma conexão são ativados sincronicamente e simultaneamente, então a força daquela conexão é seletivamente aumentada”). Este processo de treinamento é feito *in loco*, ajustando o peso das conexões baseado nas atividades dos neurônios e competitiva, na qual os neurônios da camada pós-sináptica competem entre si, com base em uma medida de similaridade com o sinal de entrada. O neurônio mais similar a esse sinal é considerado vencedor. Tal neurônio, por sua vez, excita os neurônios próximos a ele. A Distância Euclidiana é, usualmente, utilizada como medida de similaridade para descobrir o neurônio vencedor.

Cada neurônio na camada competitiva recebe a soma ponderada das entradas e tem uma vizinhança de k neurônios, vizinhança esta que pode ser organizada em 1, 2 ou n (valor) dimensões. Ao receber uma entrada, alguns neurônios serão excitados o suficiente para disparar. Cada neurônio que dispara pode ter um efeito excitatório ou inibitório em sua vizinhança. A partir daí, ocorre a inicialização dos pesos sinápticos e seguem três mecanismos básicos:

a – **Competição:** Para cada padrão de entrada, os neurônios da grade competem entre si, calculando a distância euclidiana entre seus pesos sinápticos e os valores do padrão de entrada, sendo considerado o neurônio vencedor aquele que possuir a menor distância (Aprendizagem Competitiva). O neurônio vencedor é dado pela Equação (4.1):

$$i(x) = \arg \min \| x - w_j \| \quad (4.1)$$

O vencedor determinará a localização do centro da vizinhança dos neurônios a serem treinados (excitados). Outra possibilidade é encontrar o vetor de pesos mais próximo ao vetor de entrada \mathbf{x} , ou equivalentemente, mais semelhante usando distância euclidiana representada pela Equação (4.2):

$$\| x(t) - w_v(t) \| = \min_j \| x(t) - w_j(t) \| \quad (4.2)$$

No qual v é o índice do neurônio vencedor. A unidade vencedora tem sua saída fixada em 1, enquanto as unidades que perderam a competição para aquele padrão de entrada tem suas respectivas saídas fixadas em 0 (RUMELHART e ZIPSER, 1985). Fundamentalmente existem três elementos que caracterizam o aprendizado competitivo:

- 1º Existe um conjunto de neurônios idênticos, ligados por valores de conexões sinápticas de valores distribuídos de modo aleatório;
- 2º Existe um valor Máximo bem definido para ativação dos neurônios;
- 3º Existe um mecanismo que permite que os neurônios entrem em competição pelo direito de permanecerem excitados.

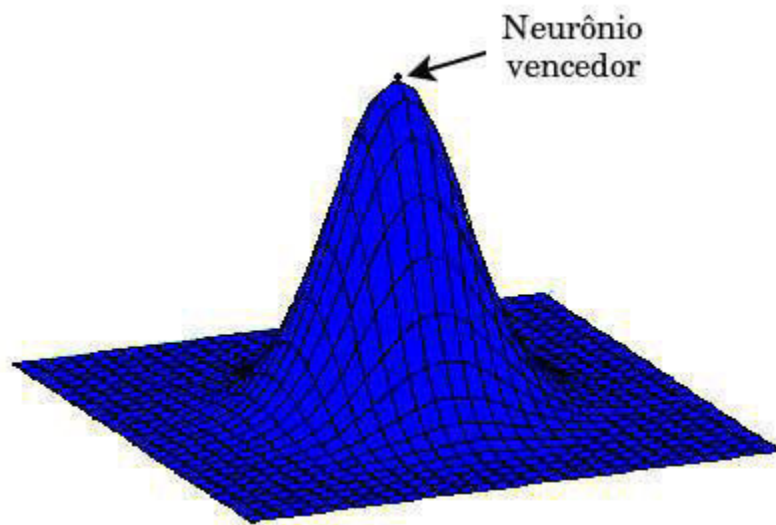
No aprendizado competitivo, entradas com semelhanças tendem a excitar o mesmo neurônio na saída (BARRETO, 1998).

b – **Cooperação:** O neurônio vencedor determina uma área ou a vizinhança topológica, na qual os neurônios vão cooperar entre si (Aprendizagem Hebbiana), ou seja, os vizinhos do neurônio vencedor são selecionados e excitados através de uma função de vizinhança.

c – **Adaptação Sináptica:** uma vez que a área de vizinhança está determinada, os neurônios vão cooperar entre si de modo a atualizarem seus pesos sinápticos, sendo que os mais

próximos do neurônio vencedor sofrem modificações mais significativas em relação aos neurônios mais distantes. Em suma: Os neurônios excitados ajustam seus pesos sinápticos quando um neurônio vence uma competição. Não apenas ele, mas também todos os neurônios localizados em sua vizinhança serão ajustados, de acordo com a função mostrada na Figura 10.

Figura 10. Saída dos elementos da vizinhança do neurônio vencedor, para efeito de ajuste dos pesos sinápticos. Perceba que os elementos mais próximos são ajustados positivamente e os mais distantes são inibidos. Os elementos muito distantes recebem um pequeno ajuste positivo de forma a evitar que os neurônios afastados nunca sejam ajustados.



Fonte: Adaptado de BRAGA (2000).

A função Gaussiana é utilizada para determinar o modo pelo qual será feita a atualização dos pesos dos neurônios na vizinhança. O neurônio vencedor estará localizado no centro da vizinhança. A Equação (4.3) representa o cálculo da excitação de um neurônio j , sendo d a distância entre o neurônio j e o neurônio vencedor i .

$$h_{ji} = \exp\left(-\frac{d_{ji}^2}{2\sigma^2}\right) \quad (4.3)$$

No qual σ representa a “largura real” da vizinhança topológica. Mensura-se o grau no qual com o qual neurônios excitados na vizinhança participam do processo de aprendizagem (HAYKIN, 1999).

Portanto, a rede neural (SOFM) é utilizada no agrupamento de dados semelhantes, aplicada quando nada se conhece sobre o conjunto dos dados (BASHEER; HAJMEER, 2000). As redes de Kohonen são utilizadas para solucionar problemas de classificação diversos. Um ponto problemático relacionado a elas: o sistema é considerado uma caixa secreta, sem certeza de convergência para redes de dimensões maiores, além do que o treinamento pode ser demorado quando o conjunto de dados a ser classificado for muito grande.

4.3.1.1 – Parâmetros de Treinamento utilizados na pesquisa

A etapa de treinamento de um SOFM requer a seleção de parâmetros livres que direcionarão o processo de treinamento cujo resultado final representa um conjunto de neurônios que caracterizam os grupos de dados encontrados nas amostras selecionadas para esta fase (amostras de treinamento). Tais parâmetros são discutidos abaixo:

A – Dimensões da rede: A SOFM utilizada no trabalho apresentou dimensões variadas, isto é, a altura e a largura da rede com número variável de neurônios. O padrão adotado manteve a mesma quantidade de neurônios nas dimensões altura e largura, ou seja, 3 x 3 com 9 neurônios, 5 x 5 com 25 neurônios, 10 x 10 com 100 neurônios e assim sucessivamente. É importante ressaltar que o tamanho da SOFM deve ser coerente em relação ao conjunto de amostras que se pretende utilizar. Caso seja muito pequena a classificação poderá acontecer de forma truncada, uma vez que a quantidade de neurônios reduzida a forçará na utilização de todos os neurônios. Nesse caso, haverá risco da rede ser induzida ao erro. Situação contrária ocorre quando a rede é muito grande em relação ao conjunto de dados amostrais. Sempre que isso acontece, poderá haver grande número de neurônios que ficarão inativos, o que indicará esforço desnecessário durante a classificação. O ideal é que haja liberdade para o ajuste da RNA com um número de neurônios que apresente coerência em função dos dados utilizados na pesquisa. Ressalta-se que, a utilização de redes neurais que apresenta um número muito grande de neurônios, pode não necessariamente ser sinônimo de resultados mais confiáveis. Isso porque a RNA pode ser extensa e possuir n neurônios que ficarão inativos ou que não serão excitados.

B – Taxas iniciais de aprendizagem e vizinhança e funções de decaimento de aprendizagem e vizinhança: De acordo Haykin (2001, p. 75), aprendizagem é o fator fundamental numa rede neural, pois dela dependerá o seu desempenho e sucesso. Tafner

(1996) afirma que o mapa de Kohonen é uma RNA competitiva, não supervisionada e traz como saída uma representação discreta dos padrões de entrada que estão agrupados por similaridade. A rede é considerada competitiva porque os neurônios pertencentes à camada de saída competem entre si para que, em um determinado momento, um único neurônio represente de modo eficaz a informação recebida pela camada de entrada da rede. O vencedor, juntamente com seus vizinhos, terá seus pesos reajustados para responder de forma eficiente ao estímulo recebido. Todo o conhecimento da rede SOFM está baseado nos pesos das conexões sinápticas (TAFNER, 1996). Logo, a rede aprende por meio de ajustes de pesos e, quando o processo se repete, aumenta o grau de instrução da RNA.

O nível de aprendizagem da rede segue um padrão decrescente e constante. Isso significa que, após várias repetições, atingiu-se a menor distância euclidiana entre o vetor de entrada e seus pesos correspondentes o que proporciona uma melhor resposta para determinados padrões de entradas (FREITAS et. al., 2003).

Para Haykin (2001, p. 493) é ideal que o fator de aprendizagem seja iniciado com valores mais baixos, próximos a 0,1 e que decresçam com o passar do tempo. Ao final, devem ser mantidos valores maiores que 0,01. A pesquisa adotou como critério de treinamento estabelecer valores máximos para o fator aprendizagem, ou seja, iniciar com taxa de aprendizado próximo a 100% e decrescer a cada ciclo do processo. Em estudos realizados sobre as taxas iniciais ideais de aprendizagem de uma rede SOFM é válido utilizar elevadas taxas iniciais e decrescer no decorrer do treinamento (WETMORE, 2005). Após o início do treinamento foram determinadas taxas baixas para a função de decaimento do aprendizado, isto é, em torno de 0,01. O objetivo é mensurar se a RNA é capaz de realizar o agrupamento dos dados apresentados seguindo um padrão de classificação, independente dos parâmetros de treinamento utilizados.

Em relação ao parâmetro vizinhança não há uma regra específica ou pré-estabelecida para ser utilizada. Tal escolha pode ser empírica e depende da necessidade para a qual a rede está sendo treinada. Há uma consideração importante a ser ressaltada: reduzir o raio de vizinhança durante o treinamento é essencial, pois favorece a orientação e estabilização da aprendizagem da rede. De acordo com Haykin (2001, p.493), a função de vizinhança deve inicialmente incluir quase todos os neurônios da rede centrada no neurônio vencedor, e então diminuir lentamente com o tempo. Durante a fase de ordenação, é permitido que a vizinhança se reduza a um valor pequeno de apenas um neurônio vizinho em torno do neurônio vencedor

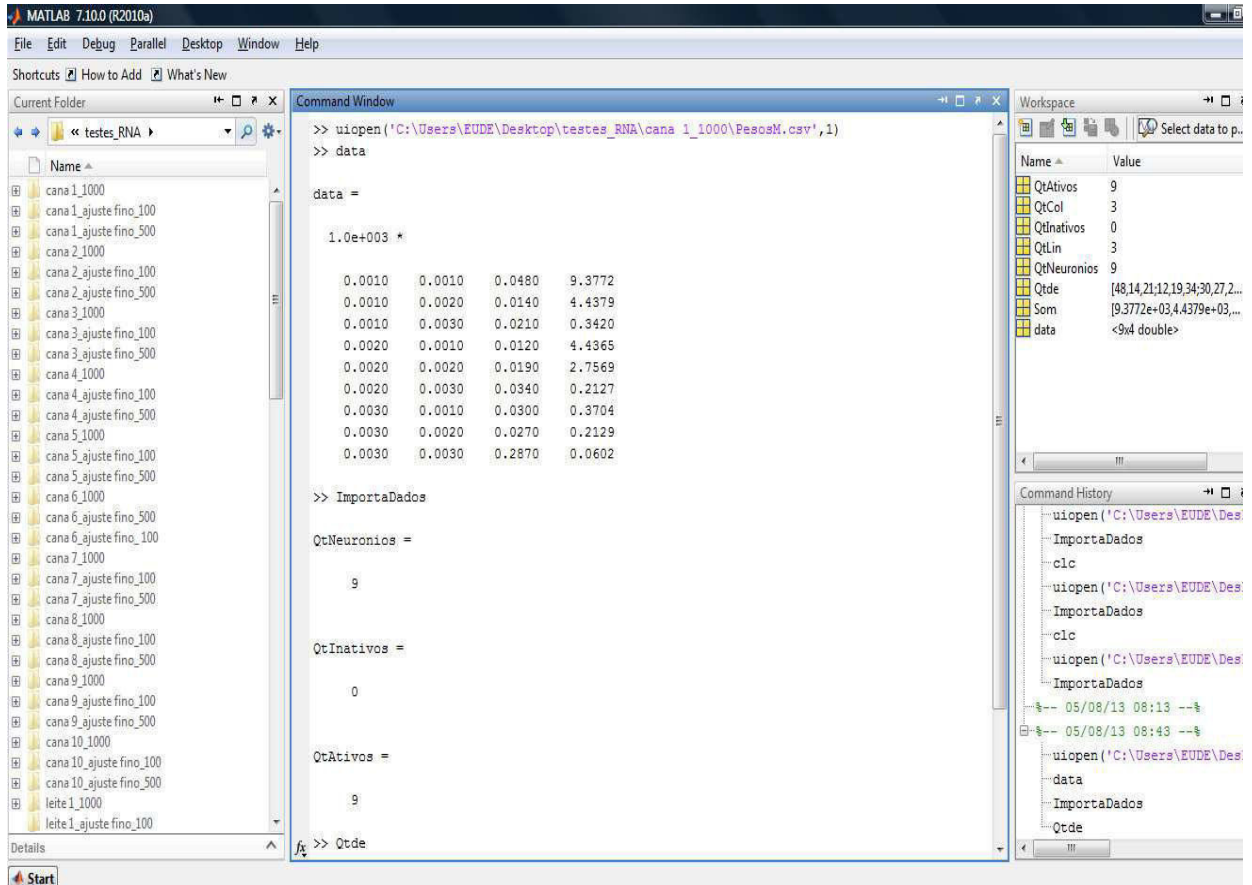
ou ao próprio neurônio vencedor. O tamanho da vizinhança pode variar durante o período de treinamento. O padrão usual é começar com uma definição maior da vizinhança, e estreitá-la conforme o treinamento procede (KOHONEN, 1997). Na pesquisa o raio de vizinhança utilizado foi proporcional ao tamanho da rede e para os ajustes finos a vizinhança utilizada foi igual a 1.

C – Ajuste fino ou Convergência: Esta é a fase de sintonia fina do mapa durante o treinamento e, geralmente, acontece com a utilização de cem a mil ciclos extras (KOHONEN, 1997). Esse processo é desenvolvido após a fase de treinamento global e depende diretamente da quantidade de neurônios ou o tamanho da rede. Vale enfatizar que a convergência de uma rede SOFM deve acontecer com uma taxa de aprendizado pequena (decrecente), ou seja, em torno de 0,02 ou 0,01. Para que haja confiabilidade no processo de treinamento, a taxa de vizinhança também deve ser pequena ou próxima de zero (KOHONEN, 1997). Para o trabalho desenvolvido, a busca pela convergência da rede ocorreu utilizando taxa de decaimento do aprendizado em torno de 0,01 e vizinhança igual a 1. Para o treinamento da rede, nessa fase a taxa de aprendizagem variou de 0,3 a 0,1 e o parâmetro vizinhança foi igual a 1.

D – Ciclos: Para a rede SOFM, define-se como ciclo a uma única apresentação à rede de todos os padrões a serem treinados. Isso significa uma apresentação de todos os n pares (entrada e saída) do conjunto de treinamento no processo de aprendizado. Se há, por exemplo, 246 padrões, um ciclo é compreendido por uma única apresentação ao mapa dos 246 padrões (KOHONEN, 2001). É importante dizer que a ordenação topológica de uma rede SOFM acontece nos ciclos iniciais, porém, a precisão do mapa dependerá do número de ciclos durante a fase de convergência ou ajuste fino. Não há regra específica para determinar o número de interações ou ciclos, mas a literatura indica que quinhentos ciclos por neurônio são suficientes para se obter resultados estatísticos esperados (KOHONEN, 1997). Logo, é ideal estimar a quantidade de ciclos em função do número de neurônios da rede. Na pesquisa foi adotado como parâmetro iniciar o treinamento com mil ciclos e, gradualmente, decrescer a quantidade avaliando o comportamento da rede em relação aos dados apresentados a ela (HAYKIN, 2001).

4.3.2 – Matlab 7.10.0 R2010a (MATrix LABoratory)

Figura 11. Interface do MATLAB 7.10.0.



Fonte: Autor (2013).

O MATLAB (Matrix Laboratory) é um software voltado para cálculos numéricos, análise de dados, cálculo com matrizes, construção de gráficos e implementação de algoritmos. Com esse software foram produzidas as figuras que demonstram o comportamento da rede SOFM durante o processo de classificação temporal. Os resultados obtidos com a utilização da rede neural SOFM foram testados com a adoção do Índice de Similaridade Intra Grupo (I_{SIG}) (descrito na seção 5 do trabalho) para mensurar o grau de proximidade das amostras de um mesmo grupo e avaliar o comportamento da rede neural e sua capacidade de fazer a classificação e a separação dos grupos de municípios com indicadores de produção similares. A utilização deste índice foi imprescindível para a finalização e validação dos resultados conclusivos da pesquisa. A ideia principal em um processo de agrupamento de dados refere-se ao fato de que dados de um mesmo grupo devem possuir mais características comuns entre si do que com dados de outro grupo. Nesse sentido,

o agrupamento consiste na divisão dos dados, com base na similaridade entre eles (JAIN e DUBES, 1988). A seguir, uma discussão teórica sobre agrupamento de dados para facilitar a compreensão do índice supracitado (I_{SIG}).

4.3.2.1 Agrupamento de dados

Análise de agrupamento é o termo utilizado ao conjunto de técnicas computacionais cujo objetivo seja o de separar objetos em grupos, baseando-se nas características que estes objetos possuem. A ideia primordial consiste em selecionar em um mesmo grupo objetos que sejam similares de acordo com algum critério pré-determinado.

A análise de dados compreende um conjunto de métodos estatísticos destinados ao tratamento de n série de dados, ou que considere a análise de duas ou mais variáveis simultaneamente (HAIR et al., 2006). Na atualidade, analisar dados de forma quantitativa já não é um processo complicado, porque com o avanço das técnicas computacionais, é possível extrair as informações, quantificá-las e qualificá-las de maneira rápida e eficiente.


Dentre os princípios básicos das técnicas de análise estatística pode-se enumerar: a- redução das dimensões dos dados; b- análise pela proximidade geométrica dos mesmos (PEREIRA, 2010). Ao considerar um espaço de duas ou n dimensões, é possível traçar uma reta entre dois pontos para representar a distância entre eles. Conhecer as distâncias entre dados é um ponto essencial para realizar análises de agrupamento. Para tal, as distâncias entre os objetos são calculadas, com todas as variáveis possíveis e, finalmente, são realizados os agrupamentos (PEREIRA, 2004). Quanto mais próximos entre si estiverem os objetos, maior será a facilidade em agrupá-los. Para agrupar objetos semelhantes selecionam-se, por meio de técnicas estatísticas, centros de referência (centroides). Quanto mais próximo do centro, maior a probabilidade de uma variável pertencer a determinado grupo. Entre os métodos mais conhecidos para determinação de distâncias estão: (1) distância Euclidiana; (2) distância de Mahalanobis; e (3) distância de Minkowsky (Mingoti, 2005).

É válido ressaltar que a pesquisa utilizou a distância Euclidiana para realizar o agrupamento dos dados.

Hipoteticamente, a Figura 12 mostra um conjunto de dados antes do agrupamento (Figura 12 (a)) e diferentes modos de separá-los em grupos. Cada cor corresponde a um

grupo: na Figura 12 (b) os dados estão separados em dois grupos; na Figura 12 (c) os dados estão separados em quatro grupos.

Figura 12: Agrupamento de um conjunto de dados (a) dados originais; (b) divisão em dois grupos; (c) divisão em quatro grupos. Cada grupo está indicado por uma cor diferente.



Fonte: Adaptado de JAIN e DUBES (2013).

No processo de agrupamento de dados há etapas que compõem o agrupamento:

1 O pré-processamento e seleção de variáveis: consiste em identificar as variáveis ou atributos mais importantes do conjunto de dados inicial. Seja houver um conjunto com n dados, o resultado será uma matriz $n \times d$, no qual d representa o número de atributos ou variáveis. Logo, um dado vai corresponder a um ponto no espaço d -dimensional, e o objetivo será identificar um conjunto de dados nesse espaço d -dimensional (JAIN e DUBES, 1988);

2 Medidas de similaridade: consiste em quantificar a proximidade entre dois dados. Há vários modos de calcular a similaridade ou dissimilaridade entre pares de dados. Uma forma muito comum é feita por meio da distância Euclidiana, que será discutida a seguir;

3 Algoritmos de agrupamento: consiste em definir o modo que se deseja realizar o agrupamento de dados (Há diversas técnicas que podem ser empregadas);

4 Validação e análise de resultados: consiste em avaliar a qualidade dos clusters encontrados uma vez que não eram conhecidos inicialmente (Esse processo é feito por índices estatísticos ou por comparação com outros algoritmos).

4.3.2.2 Medidas de similaridade

Medir a similaridade dos dados significa criar uma matriz que represente de modo quantitativo a proximidade entre os elementos de um conjunto de dados. Isso pode significar dissimilaridade (distância) ou similaridade entre duas variáveis. Nesse caso, quanto menor a

dissimilaridade ou maior similaridade entre duas variáveis, mais próximas estas se encontram. Tal matriz denomina-se matriz de proximidade (EVERITT et al., 2001).

Tais medidas podem variar de acordo o tipo e representação dos dados (binário, discreto ou contínuo). É necessário estabelecer uma escala de importância de uma variável em relação às demais. Por exemplo, uma variável pode representar o percentual de rejeição de um candidato em um processo eleitoral (o valor da variável será aferido de 0 a 100) ou indicar a distância entre dois municípios (nesse caso o valor absoluto da variável é de grande relevância) (JAIN e DUBES, 1988). A seguir serão descritas algumas medidas utilizadas para cálculo de similaridade entre dois dados e entre dois grupos.

4.3.2.3 Similaridade entre dados do mesmo grupo

A proximidade entre dois dados x_i e x_w é representada por $d(x_i, x_w)$. Uma forma de mensurar a similaridade entre variáveis contínuas é por meio da distância entre elas. A distância como métrica deve satisfazer as condições:

$$1^a - d(x_i, x_w) \geq 0;$$

$$2^a - d(x_i, x_w) = 0, \text{ se e somente se } x_i = x_w;$$

$$3^a - d(x_i, x_w) = d(x_w, x_i);$$

$$4^a - d(x_i, x_l) \leq d(x_i, x_w) + d(x_w, x_l);$$

onde $x_i, x_w, x_l \in X$.

A distância mais aplicada para calcular similaridade entre dois dados é a distância de Minkowski. Esta é calculada pela Equação (4.4), onde d corresponde ao número de variáveis do dado.

$$d(x_i, x_w) = p \sqrt[p]{\sum_{k=1}^d (|x_{ik} - x_{wk}|)^p} \quad (4.4)$$

onde $p \geq 1$.

Sendo $p = 2$, calcula-se a distância euclidiana, representada pela Equação (4.5). Esta é utilizada quando as variáveis possuem valores contínuos para avaliar a proximidade dos


dados.

distância Euclidiana, $p = 2$

$$d(x_i, x_w) = \sqrt{\sum_{k=1}^d (|x_i - x_w|)^2} \quad (4.5)$$

A seguir segue uma representação da Equação (4.6) para o cálculo da distância Euclidiana.

Figura 13. Cálculo da distância Euclidiana.



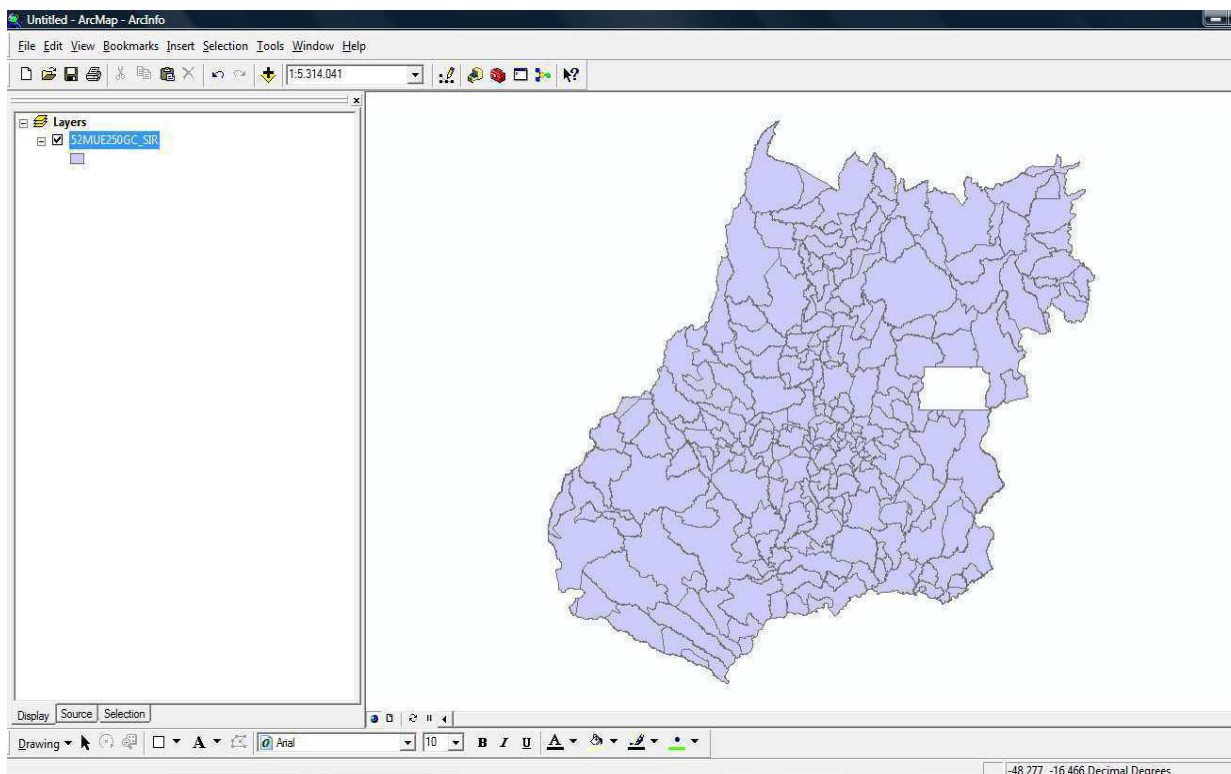
Fonte: Adaptado de (JAIN e DUBES, 1988).

O cálculo da distância Euclidiana é dado por:

$$\sqrt{4^2 + 2^2} = 4,472$$

4.3.3 – ArcGis 10.1 (ArcMap)

Figura 14. Interface do ArcGis 10.1 (ArcMap).



Fonte: Autor (2013).

O ArcGIS é um pacote de softwares de SIG – Sistema de Informações Geográficas, voltado para a elaboração de mapas, consultas e análises geocomputacionais, entre outras funcionalidades. Dentro do ArcGIS há o ArcMap, comumente chamado de ArcGIS. Ele é o desktop GIS do pacote, um software de interface gráfica, que permite a sobreposição de planos de informação vetoriais e matriciais, além de objetos gráficos, fontes (letras) e figuras, com a finalidade de mapeamento temático. Também permite pesquisas e análises espaciais, criação e edição de dados, padronização e impressão de mapas (SANTOS, 2009).

Os mapas temáticos gerados e dispostos no trabalho para mostrar o resultado do processo de detecção de mudanças dos dados relativos aos perfis de variações produtivas da cana-de-açúcar, pecuária bovina de corte e leiteira dos municípios do Estado de Goiás, referente aos anos de 1995 e 2010, foram produzidos com a utilização do pacote ArcGIS 10.1.

5 RESULTADOS E DISCUSSÃO

5.1 Índices de Análise utilizados na pesquisa

Para fins de análises comparativas é importante que os resultados obtidos possam estar dispostos de forma padronizada para facilitar a interpretação e evitar distorções ou análises incorretas a partir de um conjunto de dados. Nesse sentido, padronizar os dados significa colocá-los em uma mesma faixa de valores. Tal procedimento visa evitar que uma dimensão se predomine em relação às demais e também busca-se uma padronização para fins de análises de diferentes resultados encontrados.

Neste sentido, a presente pesquisa utiliza índices para análise e seleção de melhores configurações de SOFMs. Ambos foram normalizados pelo método Máximo – Mínimo Equalizado para calcular os padrões de erro durante o processo de classificação temporal em termos percentuais (BEVINGTON, 1992). Nesse caso, utilizam-se valores máximo e mínimo para normalizar linearmente os dados entre [0, 1]. A Equação (5.1) define o método de normalização (*nor*) acima descrito:

$$nor = \frac{x - \min(x)}{\max(x) - \min(x)} \quad (5.1)$$

Havendo necessidade de indicar valores relativos em termos percentuais basta multiplicar por 100. Logo, um erro de 0,1 é equivalente a 10%.

5.1.1 Similaridade Intra Grupos – SIG

Como descrito anteriormente, quanto maior a similaridade entre as amostras de um mesmo grupo maior será a confiabilidade da classificação. O SIG é calculado com base nos pesos das redes SOFM treinadas e nos conjuntos de treinamento, de modo que, a partir de índices percentuais de ajuste de peso dos neurônios, é possível verificar se os dados de um mesmo grupo apresentam ou não alta similaridade. Apresentam-se, a seguir, os passos para calcular o SIG:

1º passo: Calcular o Erro de Classificação da Amostra (ECA):

Define-se por ECA o erro de ajuste entre uma amostra e o neurônio que a classifica,

sendo obtido através do cálculo da distância Euclidiana (Equação 5.2), já descrita (Seção 4.3.2.3).

$$d(x, c) = \frac{\sqrt{\sum_{i=1}^D (x_i - c_i)^2}}{D} \quad (5.2)$$

Então, tem-se a Equação (5.3):

$$ECA(X_j, c) = d(X_j, c) \quad (5.3)$$

onde:

x, X_j : vetor de amostra (valor numérico);

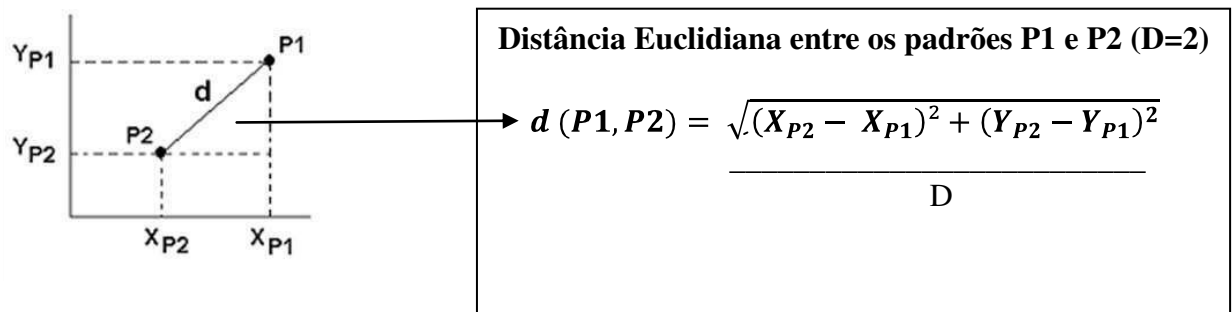
c : vetor do centroide do grupo de x (valor numérico);

D : dimensão dos dados (amostra e centroide) (valor numérico);

j : índice de uma amostra (valor numérico).

Segue abaixo, uma exemplificação do cálculo da Distância Euclidiana para um caso hipotético com dois padrões:

Padrão com 2 dimensões (X, Y)



2º passo: Calcular a Similaridade IntraGrupos (SIG).

Diante disso, a similaridade intragrupos (SIG) é definida pela medida de ajuste entre as amostras e o centroide de um grupo (Equação 5.4).

$$SIG(C_w) = \sum_{j=1}^k ECA(X_j, C_w) / k \quad (5.4)$$

onde:

constante k = quantidade de amostras classificadas por C_w

constante w = índice de um grupo

O SIG foi utilizado para mensurar o grau de similaridade entre as amostras e os centroides, por meio da aferição individual de cada centroide (grupo) em relação ao conjunto de amostras classificadas por ele. A seguir, para fins de compreensão, se considerarmos o

exemplo abaixo, o Quadro 6 demonstra o consumo de milho e soja em 20 cidades aleatoriamente. Ao definir o range das variáveis de classificação, são estabelecidos os centroides (Quadro 7). Depois de realizada a classificação, os grupos são definidos a partir dos centroides. Logo, a similaridade intragrupos (SIG) é definida pela medida de ajuste entre as amostras e o centroide de um grupo (ECA).

Quadro 6: Consumo de milho e soja em 20 cidades.

	A	B	C
	CIDADE	MILHO	SOJA
1	A	35	40
2	B	60	68
3	C	200	500
4	D	1000	5000
5	E	0	59
6	F	56	600
7	G	87	53
8	H	90	60
9	I	66	34
10	J	13	87
11	K	16	37
12	L	47	25
13	M	39	13
14	N	500	90
15	O	200	98
16	P	450	47
17	Q	20	32
18	R	70	222
19	S	55	45
20	T	78	58

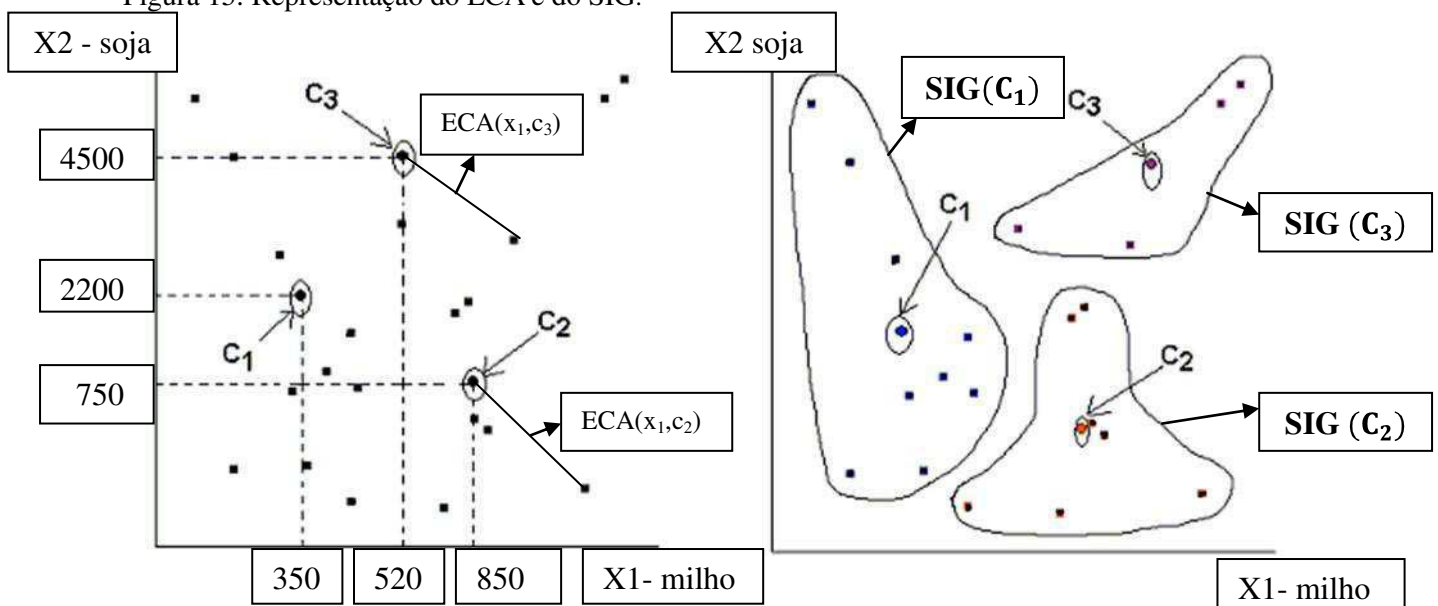
Fonte: Autor (2013).

Quadro 7: Definição do range de classificação e centroides.

Range das variáveis de classificação:	
Milho: Mínimo = 0	Máximo = 1000
Soja: Mínimo = 32	Máximo = 5000
1°- Centroide C_1 : (350, 750)	
2°- Centroide C_2 : (850, 2200)	
3°- Centroide C_3 : (520, 4500)	

Fonte: Autor (2013).

Figura 15: Representação do ECA e do SIG.



Fonte: Adaptado de SALVINI e CARVALHO (2001).

A partir disso, calcula-se o Índice de Similaridade Intra Grupo (I_{SIG}) representado por:

$$I_{SIG}(ci) = \frac{SIG(ci) - \min\{X\}}{\Delta X} \quad (5.5)$$

onde:

$$\Delta X = \max\{X\} - \min\{X\}$$

De acordo com a Equação 5.5, $0 \leq I_{SIG} \leq 1$, sendo que valores próximos de zero indicam alta similaridade entre as amostras de um grupo e valores próximos a um indicam baixa similaridade entre as amostras de um grupo.

Diante do exposto, a pesquisa adotou a SIG e o Índice de Similaridade Intra Grupos (I_{SIG}) para avaliar classificação temporal realizada utilizando dados relativos a produção dos municípios goianos. Para uma análise técnica e estatisticamente aceitável, quanto menor forem os valores percentuais encontrados para o I_{SIG} , melhor serão os resultados, pois indicam alto grau de similaridade entre as amostras classificadas por um neurônio e seu centroide.

5.2 A sinclassificação temporal aplicada à produção de cana-de-açúcar, pecuária bovina de corte e leiteira em Goiás

Em qualquer dimensão de classificação, já discutida anteriormente, é importante ressaltar que *classificar* significa buscar o reconhecimento de componentes em função de um critério estabelecido, separando em grupos que apresentam aspectos ou padrões de similaridade. A ideia final será a produção de um mapa de mudança com grupos ou temas definidos em termos quantitativos para serem analisados e interpretados de acordo com a necessidade e intenção da pesquisa.

As análises e os resultados obtidos foram alcançados utilizando dados relativos à produção de cana-de-açúcar, pecuária bovina de corte e leiteira, com base nos indicadores produtivos dos 246 municípios goianos, disponibilizados pelo IBGE, ano 1995 e 2010. A classificação proposta foi realizada utilizando como ferramenta uma rede neural artificial do tipo SOFM que possui como princípio básico de funcionamento uma aprendizagem não supervisionada. Nesse formato de aprendizagem, a rede neural deverá ser treinada

normalmente, porém, como não houve supervisão externa, conseqüentemente, não há exemplos rotulados da função a ser apreendida pela RNA para conduzir o seu treinamento. Na fase de treinamento de SOFMs foram adotados parâmetros (Tabela 1) referenciados na literatura.

Tabela 1: Parâmetros de treinamento da rede SOFM.

Treinamento da Rede SOFM	
Parâmetros	Crítérios
Dimensões da rede: altura e largura.	Conforme a literatura, o tamanho de uma rede SOFM deve ser adequado ao volume de dados amostrais que se pretenda utilizar na pesquisa. O pesquisador deve ser cuidadoso em um aspecto: redes pequenas em que todos os neurônios sejam utilizados pode provocar uma classificação forçada e os resultados obtidos serão passíveis de erros. A utilização de redes com número grande de neurônios no qual haja inúmeros neurônios inativos também se torna desnecessária. O ideal será ajustar as dimensões da SOFM ao volume de dados e, com margem para que existam mais neurônios ativados e poucos inativos, ou seja, a rede trabalhará com uma margem de folga para que a classificação ocorra o que se traduzirá em resultados precisos (KOHONEN, 1982).
Taxas iniciais de aprendizagem e vizinhança	A literatura faz referência a estes parâmetros destacando um aspecto primordial: na fase de ordenação ou auto-organização, os valores iniciais para taxa de aprendizagem devem começar com um valor maior e decrescer gradualmente, permanecendo acima de 0,01. Isso se faz necessário para que os neurônios vencedores e seus vizinhos tenham oportunidade de um aprendizado máximo até atingir a um grau mínimo de aprendizagem, em que o processo se estabilize e não haja mais aprendizagem. No que se refere à taxa de vizinhança, o procedimento a ser seguido deve ser: a inclusão inicial de quase todos os neurônios na rede centrados no neurônio vencedor. Em seguida, deve-se reduzir o raio lentamente com o passar do tempo. Esse procedimento visa garantir que não somente o neurônio vencedor aprenda, mas todos os seus vizinhos, de forma que a aprendizagem da rede seja homogênea (HAYKIN, 2001).

Funções de decaimento de aprendizagem e vizinhança	Para tais parâmetros, as pesquisas já realizadas levam às seguintes orientações: o nível de aprendizagem da rede segue um padrão decrescente e constante. Isso quer dizer que, após várias repetições, atingiu-se a menor distância euclidiana entre o vetor de entrada e os pesos sinápticos dos vencedores e seus vizinhos correspondentes, o que proporciona uma melhor resposta para determinados padrões de entradas. Esse procedimento assegura que o processo de aprendizagem seja contínuo até que a rede atinja um limiar e se estabilize (KOHONEN, 1997).
Ajuste fino ou convergência	Na literatura, essa fase do processo adaptativo da rede irá permitir uma quantificação estatística apurada do conjunto de valores de entrada, ou seja, é uma fase que representa a sintonia fina do mapa durante o treinamento. Para se obter resultados satisfatórios dentro de padrões estatísticos, o parâmetro taxa de aprendizagem precisa manter-se em um valor pequeno durante a fase de convergência, não devendo cair a zero em nenhum momento. Caso contrário, a rede poderá ficar “presa” a um nível onde não ocorram mais modificações na matriz dos pesos (indicando convergência) e mesmo assim não produzirá “bons” resultados. A função de vizinhança deve conter somente os vizinhos mais próximos de um neurônio vencedor, podendo, até mesmo, reduzir o número de neurônios vizinhos mais próximos a um, ou mesmo a zero (HAYKIN, 2001).
Quantidade de ciclos	Não há regra específica para determinar o número de interações ou ciclos a serem utilizados em uma rede SOFM, mas a literatura indica que, quinhentos ciclos por neurônio são suficientes para se obter resultados estatísticos esperados (KOHONEN, 1997). Segundo Haykin (2009), a fase de ordenação pode exigir 1000 interações ou mais e o ajuste fino deve ocorrer com um número menor de neurônios, nunca inferior a cem (100).

Fonte: HAYKIN (2001); KOHONEN (1997); KOHONEN (1982). Elaborado por: Autor (2013).

5.2.1 Experimentos de classificação realizados com a rede SOFM

A fase de experimentação foi essencial para o processo de classificação. Os testes foram realizados com os dados referentes aos indicadores de produtividade para a cana-de-açúcar, pecuária bovina de corte e leiteira, de todos os municípios goianos. Cada teste seguiu o padrão de treinamento da rede, utilizando os parâmetros já descritos na Seção 4.3.1.1 e referenciados na Tabela 1. Para avaliar o comportamento da rede SOFM durante o processo de classificação foi utilizado o índice I_{SIG} com o objetivo de mensurar se o agrupamento realizado atendeu aos princípios de similaridade intragrupo (Seção 4.3.2.1).

5.2.1.1 Parâmetros de treinamento da rede SOFM

As configurações adotadas para o treinamento da rede SOFM durante as análises relacionadas aos indicadores de produtividade de cana-de-açúcar e rebanho bovino de corte e leite dos municípios goianos estão discriminados nas Tabelas 2, 3 e 4 abaixo relacionadas.

Tabela 2: Configurações de treinamento: cana-de-açúcar.

Configurações	Parâmetros de treinamento				
	Dimensões	Ciclos	Taxa aprendizagem	Raio de Vizinhança	Decaimento
CO3	3 x 3	1000	1	2	0,01
CC3	3 x 3	500	0,3	1	0,01
CO5	5 x 5	1000	1	3	0,01
CC5	5 x 5	500	0,3	1	0,01
CO7	7 x 7	1000	1	4	0,01
CC7	7 x 7	500	0,3	1	0,01
CO9	9 x 9	1000	1	5	0,01
CC9	9 x 9	500	0,3	1	0,01
CO11	11 x 11	1000	1	6	0,01
CC11	11 x 11	500	0,3	1	0,01
CO13	13 x 13	1000	1	7	0,01
CC13	13 x 13	500	0,3	1	0,01
CO15	15 x 15	1000	1	8	0,01
CC15	15 x 15	500	0,5	2	0,01
CO17	17 x 17	1000	1	9	0,01

CC17	17 x 17	500	0,5	2	0,01
CO19	19 x 19	1000	1	10	0,01
CC19	19 x 19	500	0,5	1	0,01

Fonte: Autor (2013).

As configurações demonstradas na Tabela 2 referem-se aos testes realizados com os indicadores de produção para a cana-de-açúcar, sendo a sigla CO e CC respectivamente, cana fase ordenação e cana fase convergência. Portanto, CO3 significa cana fase ordenação em rede com dimensão 3 x 3 e CC3 indica cana fase convergência em rede de mesma dimensão e assim sucessivamente.

Tabela 3: Configurações de treinamento: rebanho bovino de corte.

Configurações	Parâmetros de treinamento				
	Dimensões	Ciclos	Taxa aprendizagem	Raio de Vizinhaça	Decaimento
RO3	3 x 3	1000	1	2	0,01
RC3	3 x 3	500	0,3	1	0,01
RO5	5 x 5	1000	1	3	0,01
RC5	5 x 5	500	0,3	1	0,01
RO7	7 x 7	1000	1	4	0,01
RC7	7 x 7	500	0,3	1	0,01
RO9	9 x 9	1000	1	5	0,01
RC9	9 x 9	500	0,3	1	0,01
RO11	11 x 11	1000	1	6	0,01
RC11	11 x 11	500	0,3	1	0,01
RO13	13 x 13	1000	1	7	0,01
RC13	13 x 13	500	0,3	1	0,01
RO15	15 x 15	1000	1	8	0,01
RC15	15 x 15	500	0,3	1	0,01
RO17	17 x 17	1000	1	9	0,01
RC17	17 x 17	500	0,5	1	0,01
RO19	19 x 19	1000	1	10	0,01
RC19	19 x 19	500	0,3	1	0,01

Fonte: Autor (2013).

As configurações demonstradas na Tabela 3 referem-se aos testes realizados com os indicadores de produção para o rebanho bovino de corte, sendo a sigla RO e RC respectivamente, rebanho fase ordenação e rebanho fase convergência. Portanto, RO3 significa rebanho fase ordenação em rede com dimensão 3 x 3 e RC3 indica rebanho fase convergência em rede de mesma dimensão e assim sucessivamente.

Tabela 4: Configurações de treinamento: rebanho bovino de leite.

Configurações	Parâmetros de treinamento				
	Dimensões	Ciclos	Taxa aprendizagem	Raio de Vizinhaça	Decaimento
LO3	3 x 3	1000	1	2	0,01
LC3	3 x 3	500	0,3	1	0,01
LO5	5 x 5	1000	1	3	0,01
LC5	5 x 5	500	0,3	1	0,01
LO7	7 x 7	1000	1	4	0,01
LC7	7 x 7	500	0,3	1	0,01
LO9	9 x 9	1000	1	5	0,01
LC9	9 x 9	500	0,3	1	0,01
LO11	11 x 11	1000	1	6	0,01
LC11	11 x 11	500	0,3	1	0,01
LO13	13 x 13	1000	1	7	0,01
LC13	13 x 13	500	0,3	1	0,01
LO15	15 x 15	1000	1	8	0,01
LC15	15 x 15	500	0,3	1	0,01
LO17	17 x 17	1000	1	9	0,01
LC17	17 x 17	500	0,5	1	0,01
LO19	19 x 19	1000	1	10	0,01
LC19	19 x 19	500	0,3	1	0,01

Fonte: Autor (2013).

As configurações demonstradas na Tabela 4 referem-se aos testes realizados com os indicadores de produção para o rebanho bovino de leite, sendo a sigla LO e LC respectivamente, leite fase ordenação e leite fase convergência. Portanto, LO3 significa leite fase ordenação em rede com dimensão 3 x 3 e LC3 indica leite fase convergência em rede de mesma dimensão e assim sucessivamente.

Para cada indicador de produção, a classificação temporal foi realizada obedecendo duas etapas de treinamento da rede SOFM: ordenação ou auto-organização e convergência ou ajuste fino. Para todos os testes realizados foram utilizados os parâmetros e suas variantes conforme já descritos e referenciados (Tabela 1).

5.2.1.2 Resultados obtidos para o processo de classificação temporal

Os resultados alcançados foram avaliados a partir de análises do índice I_{SIG} . Conforme Seção 5.1.1, o I_{SIG} reflete a dispersão relativa das amostras dentro dos grupos gerados por uma dada rede SOFM treinada. Desta forma, a qualidade de ajuste dos centroides é inversamente proporcional a este índice. A seguir, os Quadros 8 (área plantada de cana-de-açúcar em ha), 9 (pecuária bovina de corte em cabeças) e 10 (pecuária bovina leiteira em litros) demonstram os resultados obtidos com a classificação temporal para os indicadores de produção dos 246 municípios goianos. Para cada configuração testada, a rede indicou a quantidade de neurônios ativados e inativos. Isso permitiu avaliar o comportamento da rede durante a classificação.

Quadro 8: Resultados da classificação temporal (área plantada de cana-de-açúcar (em ha)).

Configuração	Neurônios ativos	Neurônios inativos	SIG	I_{SIG}
CO3	9	0	1217	1%
CC3	9	0	1011	2%
CO5	23	2	702	1%
CC5	20	5	434	1%
CO7	33	16	404	1%
CC7	31	18	281	0,40%
CO9	41	40	265	0,40%
CC9	37	44	169	0,20%
CO11	70	51	115	0,10%
CC11	51	70	206	0,20%
CO13	75	94	104	0,80%
CC13	60	109	126	0,40%
CO15	68	157	137	0,60%
CC15	69	156	91	0,50%
CO17	91	198	101	0,50%

CC17	68	221	86	0,20%
CO19	84	277	85	0,30%
CC19	77	284	6	0,30%

Fonte: Autor (2013).

Quadro 9: Resultados da classificação temporal (pecuária bovina de corte (nº de cabeças)).

Configuração	Neurônios ativos	Neurônios inativos	SIG	I_{SIG}
RO3	8	1	20725	3%
RC3	9	0	17177	3%
RO5	23	2	10145	1%
RC5	23	2	7718	1%
RO7	46	3	5744	1%
RC7	31	18	5573	0,7%
RO9	45	36	3037	0,4%
RC9	36	45	2638	0,3%
RO11	86	35	2115	0,3%
RC11	35	86	2924	0,4%
RO13	106	63	1837	0,2%
RC13	37	132	3417	0,3%
RO15	119	106	1649	0,3%
RC15	101	124	1274	0,4%
RO17	138	151	1431	0,2%
RC17	29	260	4818	0,4%
RO19	140	221	1103	0,2%
RC19	51	310	1593	0,2%

Fonte: Autor (2013).

Quadro 10: Resultados da classificação temporal (pecuária bovina leiteira (em litros)).

Configuração	Neurônios ativos	Neurônios inativos	SIG	I_{SIG}
LO3	8	1	2709	2%
LC3	9	0	3590	3%
LO5	25	0	1414	1%

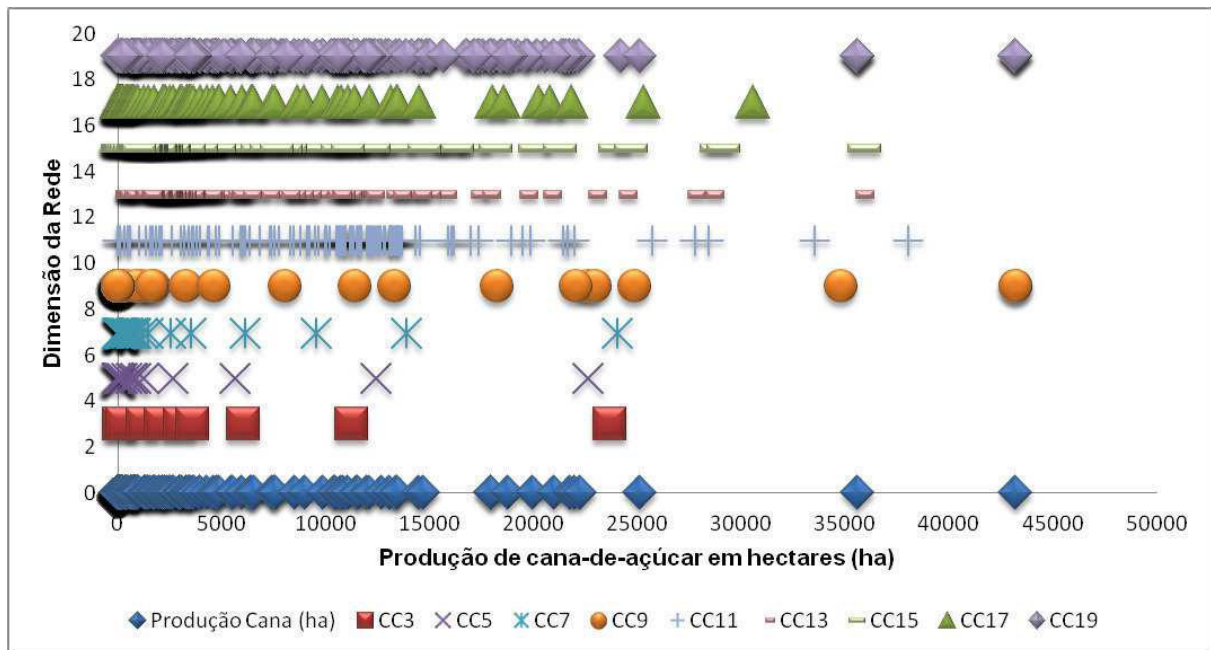
LC5	14	11	1122	0,7%
LO7	42	7	878	0,6%
LC7	26	23	677	0,4%
LO9	71	10	534	0,4%
LC9	39	42	457	0,2%
LO11	91	30	411	0,2%
LC11	28	93	662	0,2%
LO13	103	66	266	0,1%
LC13	53	116	435	0,06%
LO15	137	88	255	0,3%
LC15	76	149	243	0,5%
LO17	139	150	184	0,2%
LC17	35	254	242	0,3%
LO19	155	206	175	0,4%
LC19	34	327	602	0,2%

Fonte: Autor (2013).

Os resultados obtidos demonstram que o processo de classificação temporal realizado para os três indicadores de produção dos municípios goianos mostrou-se aceitável para padrões de similaridade intra grupo. O Índice de Similaridade Intra Grupo (I_{SIG}) adotado variou em um intervalo [0,1] e apresentou resultados baixos próximos a 0, o que indica que a Similaridade Intra Grupos é alta. A partir disso, é possível afirmar que a pesquisa obteve resultados que confirmam a realidade dos municípios do Estado de Goiás relativos à produtividade de cana-de-açúcar, quantitativo do rebanho bovino de corte e produção bovina leiteira.

O Gráfico 2 demonstra o comportamento da rede SOFM ao realizar a classificação temporal para a área plantada de cana de açúcar (em hectare). No eixo vertical estão representadas as diferentes dimensões de redes (3, 5, 7, 9, 11, 13, 15, 17 e 19) utilizadas na classificação e o eixo horizontal representa os dados de produção escolhidos para a pesquisa. Em uma análise geral, os resultados representados permitem inferir que a distribuição estatística dos grupos acompanha a dimensão dos dados, sendo a rede SOFM capaz de ajustar-se a realidade dos mesmos. O comportamento da rede SOFM observado para a pecuária bovina de corte e leite foi similar ao demonstrado para a cana de açúcar.

Gráfico 2: Diferentes dimensões de redes e a distribuição estatística dos dados (produção de cana em ha).



Fonte: Autor (2013).

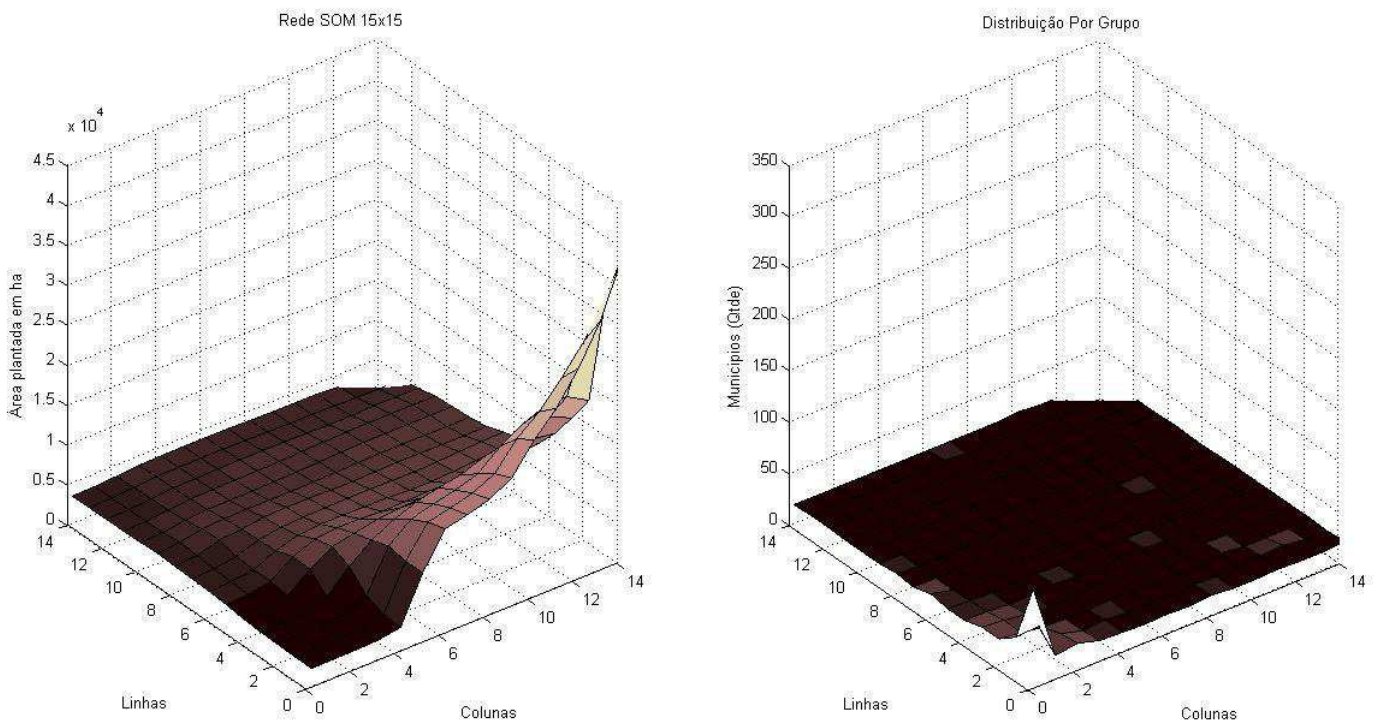
O Gráfico 2 demonstra os dados de produção de cana-de-açúcar, indicando que há um maior quantitativo de municípios com baixa produção e poucos municípios com elevada produtividade. No eixo horizontal está indicada a produção em hectares e no eixo vertical estão indicadas as diferentes dimensões de redes neurais testadas. Conclusivamente, em todas as dimensões de RNA utilizadas o comportamento manteve-se similar em relação ao padrão dos municípios goianos.

É importante enfatizar que a representação do Gráfico 2 demonstra que, independentemente do tamanho da rede SOFM utilizada, o comportamento observado em todos os testes foi similar para a distribuição estatística dos grupos em relação a dimensão do conjunto de dados das amostras pesquisadas. Portanto, a rede ajusta-se de forma coerente diante da realidade dos dados e do perfil produtivo dos municípios goianos (fato já verificado pelos valores I_{SIG} obtidos). Vale ressaltar que há maior quantidade de municípios com baixa produção e menor quantidade com alta produtividade. Esse perfil ficou evidenciado na distribuição dos grupos diante das classificações realizadas com redes de dimensões variadas, ou seja, em todas as configurações testadas, o método criou mais grupos de baixos produtores e menos grupos de altos produtores, refletindo assim a distribuição estatística dos conjuntos de treinamento em suas configurações finais.

5.2.1.3 Comportamento da Rede SOFM e Distribuição por Grupo

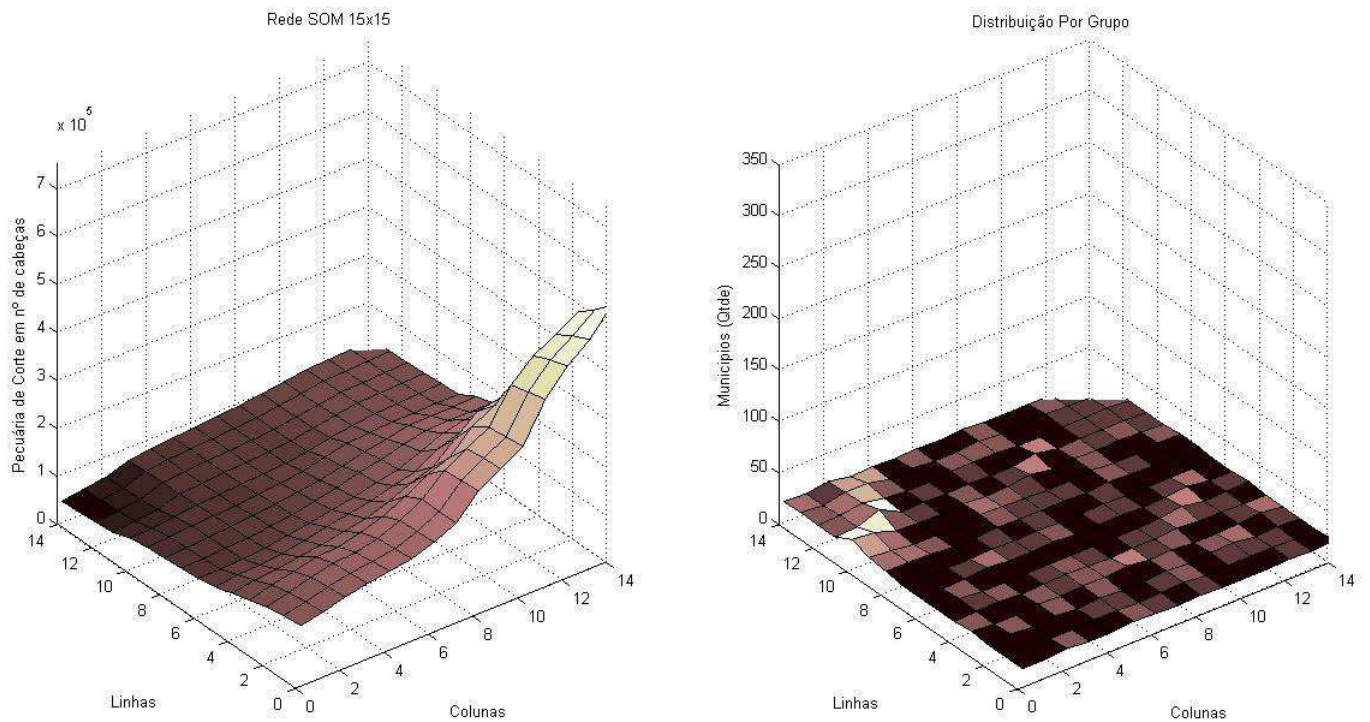
As Figuras 16, 17 e 18 demonstram o comportamento da Rede SOFM e a Distribuição por Grupo, respectivamente para: a área plantada de cana-de-açúcar em hectares, pecuária de corte em nº de cabeças e a produção leiteira em litros para casos de classificações com redes 15 x 15. Outras configurações foram testadas e são apresentadas no apêndice B. As análises abaixo apresentadas servem a todas as dimensões de rede utilizadas neste trabalho, pois, como é de se esperar, o comportamento da rede não se alterou para diferentes geometrias. Os demais testes realizados estão dispostos no apêndice B.

Figura 16: Comportamento relativo à área plantada de cana-de-açúcar. À esquerda Rede SOFM 15 x 15 (classificação relativa a produtividade); a direita Distribuição por Grupo (Quantitativo de municípios agrupados).



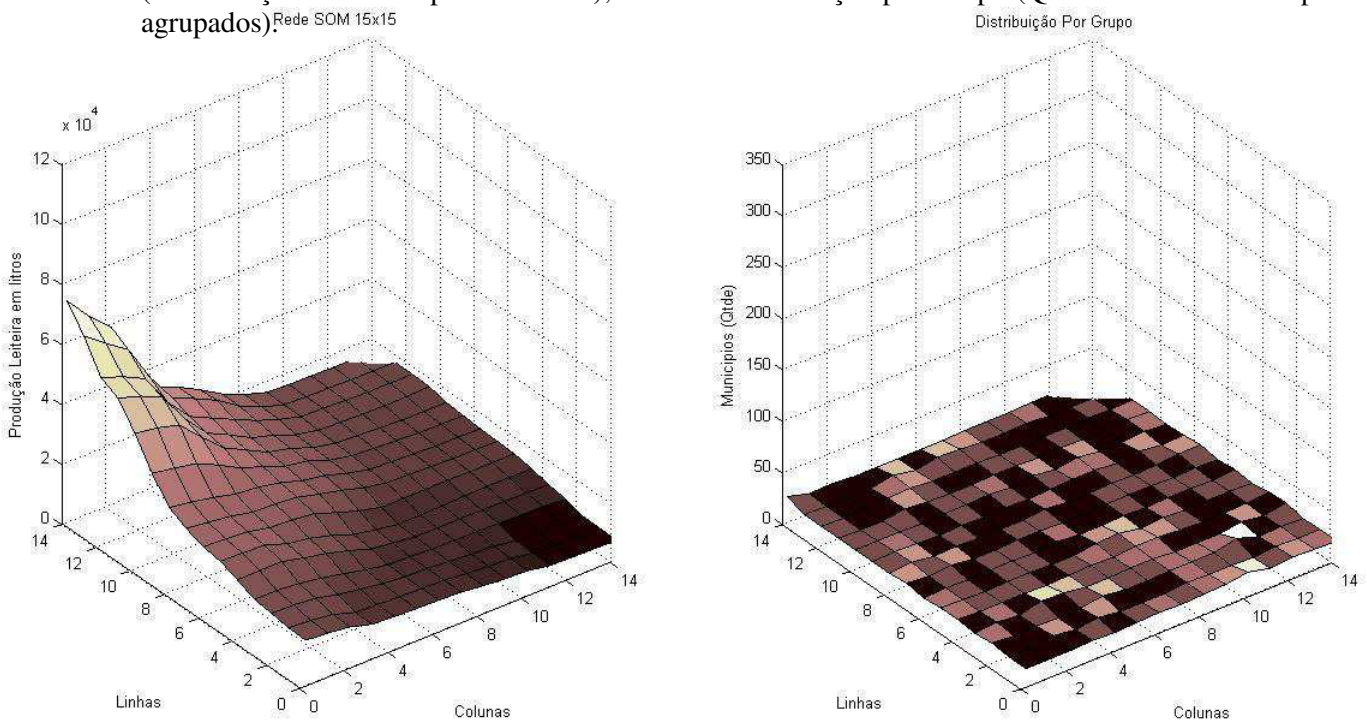
Fonte: Autor (2013).

Figura 17: Comportamento relativo à pecuária de corte em nº de cabeças. À esquerda Rede SOFM 15 x 15 (classificação relativa a produtividade); a direita Distribuição por Grupo (Quantitativo de municípios agrupados).



Fonte: Autor (2013).

Figura 18: Comportamento relativo à produção leiteira em litros. À esquerda Rede SOFM 15 x 15 (classificação relativa a produtividade); a direita Distribuição por Grupo (Quantitativo de municípios agrupados).



Fonte: Autor (2013).

Ao analisar a Figura que representa a Rede SOFM é possível interpretar, a partir do eixo vertical (z), que demonstra a área plantada de cana-de-açúcar em hectares, pecuária de corte em nº de cabeças e a produção leiteira em litros, um comportamento padronizado, onde as regiões mais escuras da rede (baixos valores em z) refletem baixa produção e as mais claras (altos valores em z) demonstram alta produtividade. Já a Figura que indica a distribuição por grupo, demonstrando a quantidade de municípios no eixo vertical (z), a interpretação permite afirmar que regiões mais escuras refletem menor quantidade de municípios, enquanto as mais claras indicam maior quantidade de municípios agrupados. O comportamento da rede SOFM em relação à distribuição dos municípios por grupo indica que há maior quantidade de municípios relativos aos grupos relacionados com baixa produção e menor quantidade de municípios nos grupos vinculados à altas produtividades.

Mediante os resultados produzidos com a classificação temporal realizada pela rede SOFM, uma pergunta importante deve ser feita e respondida: o comportamento e os resultados fornecidos com a classificação temporal refletem a realidade dos municípios goianos quanto ao perfil produtivo das culturas pesquisadas?

A resposta é positiva ou sim. A partir de inúmeros indicadores oficiais divulgados pelo IBGE e SEGPLAN – GO, verifica-se que o comportamento produtivo relativo à produção de cana-de-açúcar, pecuária bovina de corte e leiteira indica grandes variações de produtividade entre os municípios. Logo, é possível perceber que as configurações finais dos grupos refletem a realidade goiana para os indicadores de produção pesquisados, ou seja, maior quantidade de municípios com baixa produção e poucos municípios com elevada produtividade.

5.2.1.4 Resultados da Sinclassificação

A rede SOFM treinada para executar a sinclassificação dos dados da pesquisa apresentada, demonstrou coerência em relação aos resultados obtidos. Ao realizar o treinamento, levaram-se em consideração todos os parâmetros necessários para o funcionamento do software. As dimensões (altura x largura) utilizadas para determinar a quantidade de neurônios foram flexíveis e os testes aconteceram com redes que possuíam entre nove (9) a trezentos sessenta e um (361) neurônios. O uso de redes com dimensões variadas foi válido, pois ficou perceptível que todas apresentaram comportamento semelhante

diante do conjunto de amostras de entrada apresentadas para que ocorresse a classificação.

Os valores iniciais para as taxas de aprendizagem e vizinhança utilizadas seguiram referenciais bem descritos na literatura e na pesquisa (ver Seção 5.2). Inicialmente, a aprendizagem foi alta (100%) e a vizinhança obedeceu a proporções de acordo com o tamanho da rede testada, como por exemplo, uma rede 5 x 5 com vizinhança inicial igual a 5 e assim sucessivamente. A quantidade de ciclos utilizados durante o treinamento foi definida de acordo com orientações sugeridas na literatura. Trabalhou-se com mil (1000) ciclos iniciais e, durante a fase de convergência e ajuste fino, decresceu-se o número para quinhentos (500), até chegar a um mínimo de cem (100) ciclos. O decaimento da aprendizagem e vizinhança seguiu padrões científicos já referenciados. Após o início do treinamento foram determinadas taxas baixas para o decaimento do aprendizado, isto é, iniciando com valores iguais 0,1 e decrescendo até 0,01. Em relação à função de decaimento da vizinhança foi proporcional ao decréscimo do decaimento da aprendizagem, ou seja, não inferior a 0,01.

Diante do exposto, os resultados obtidos com a classificação temporal, utilizando dados relacionados à produção de cana-de-açúcar (área plantada em hectares), pecuária bovina de corte (nº de cabeças) e leiteira (quantidade de litros) dos municípios goianos, podem ser considerados satisfatórios para padrões estatísticos, pois a rede SOFM conseguiu realizar o agrupamento com base na similaridade dos dados e o seu comportamento demonstrou precisão, quando comparados aos índices oficiais disponibilizados pelo Governo de Goiás e pelo IBGE, relativos aos três perfis de produção pesquisados para os 246 municípios goianos. Logo, o comportamento da rede SOFM reflete a realidade dos dados amostrais que indicam maior quantidade de municípios com baixa produtividade e menor quantidade com alta produtividade.

5.3 Aplicabilidade e vantagens da utilização do método de classificação proposto

Através da metodologia e ferramenta utilizada na pesquisa proposta, cabe ressaltar as inúmeras vantagens em sua aplicabilidade:

1 – **A escalabilidade do método:** o trabalho desenvolvido teve como área de abrangência os municípios goianos, mas pode ser aplicada a qualquer estado, região e/ou municípios brasileiros. Há a possibilidade de adotar uma escala que possa abranger microdimensões a macrodimensões utilizando dados amostrais que envolvam padrões diversificados como, por

exemplo, índices econômicos de safra agrícola, de crescimento demográfico, de mapeamento de doenças em nível endêmico (restrito) ou epidêmico (amplo), dentre outros;

2 – A redução da dimensionalidade dos dados: a rede SOFM consegue realizar a classificação, independente da quantidade dos dados amostrais fornecidos a ela. Isso significa que, uma pesquisa de classificação que ora seria feita por comparação manual e demandaria grande esforço físico e tempo do pesquisador, pode ser feita com economia de tempo e de custos tanto para quem pesquisa, quanto para o órgão financiador;

3 – A intercomunicação entre softwares: a rede SOFM, ao ser treinada e utilizada, consegue exportar os resultados em uma formatação padronizada de fácil interação com outros softwares que são capazes de transformar resultados numéricos em interfaces cartográficas (mapas) de simples interpretação visual. Nesse sentido, a pesquisa pode ser desenvolvida em âmbito multidisciplinar e envolver pesquisadores de diversas áreas e instituições.

Diante do comportamento apresentado pela rede, é possível afirmar que a utilização dessa ferramenta tecnológica é viável e útil para realizar classificação temporal aplicada a diversos indicadores relacionados, não somente ao setor produtivo, mas em outras situações como classificação temporal para densidade demográfica de um município ou estado; identificação de espécies nativas de uma determinada área ecológica; mensurar níveis de desmatamento de uma determinada região; mapeamento dos índices de ocorrência de uma determinada doença em um grupo populacional, dentre inúmeras outras possibilidades que se mostram favoráveis para a realização de classificação temporal com o objetivo de conhecer ou monitorar determinada variável desconhecida.

Outro ponto positivo relacionado à utilização da ferramenta demonstrada, refere-se ao fato de que os dados gerados pela rede DMB – SOFM serem compatíveis para utilização em outras ferramentas tecnológicas (softwares) como, por exemplo, o ArcGis (ArcMap) que são usados com frequência em Sistemas de Informação Geográfica (SIG) e permitem a análise, gestão ou representação do espaço e dos fenômenos que nele ocorrem. A partir daí, torna-se possível a produção de mapas cartográficos que demonstram os diversos fenômenos que ocorrem no planeta quer sejam por fatores naturais ou antrópicos. Destaca-se a ocorrência de

desmatamentos, queimadas, fenômenos meteorológicos (furacões e tufões), alagamento de regiões (lagos de usinas hidrelétricas), enchentes urbanas, ocupação urbana desordenada em área de risco como encostas e ribeirinhas, dentre outros.

Mediante ao apresentado, pode-se concluir que a utilização de ferramentas computacionais com as redes neurais artificiais em uma abordagem metodológica de classificação não supervisionada como o modelo apresentado anteriormente, demonstra apresentar inúmeras vantagens e motivos que justifiquem sua utilização. Dentre elas destaca-se:

- 1° São capazes de executar tarefas que métodos lineares não conseguem em função de seu aspecto não linear;
- 2° A transformação das variáveis é automática no decorrer do processo computacional da rede sem a necessidade de interferência humana;
- 3° Se uma unidade neuronal artificial falhar, outra assume a função de dar continuidade ao processamento dos dados;
- 4° Uma RNA aprende e não precisa ser reprogramada;
- 5° A sua utilização pode ser aplicada em diversas áreas do conhecimento científico;
- 6° São capazes de aprender, armazenar e generalizar o conhecimento, tendo capacidade de descrever o todo a partir de algumas partes;
- 7° São capazes de realizar tarefas de alta complexidade em um curto espaço de tempo.

5.4 A detecção de mudança temporal relacionada à área plantada de cana-de-açúcar, rebanho de corte bovino e produção leiteira dos municípios goianos

O processo de detecção de mudança temporal aplicado aos indicadores de produção dos municípios goianos demonstrou, como se esperava, um comportamento que condiz com a realidade do Estado de Goiás. Buscando otimizar as análises e os resultados, as demonstrações que serão feitas a seguir referem-se a uma rede de Kohonen de dimensão 5 x 5, o que significa um total de vinte e cinco neurônios. É importante lembrar que já se comprovou que a rede foi capaz de classificar os dados em diferentes dimensões, logo, a

escolha da dimensionalidade da RNA dependerá do quantitativo de dados que a pesquisa contenha. No caso do trabalho realizado, percebeu-se que uma dimensão 5 x 5 mostrou-se suficiente para detectar mudanças.

5.4.1 A Detecção de Mudanças para a Área Plantada de Cana-de-Açúcar em Goiás

Ao considerar a rede de dimensão 5 x 5, a mesma agrupou os municípios em 25 categorias (classes/grupos) e, cada neurônio ativado definiu um centróide ou peso referente ao nível de produção municipal. Para a cana-de-açúcar foram definidos os pesos e os grupos conforme apresentados no Quadro 11:

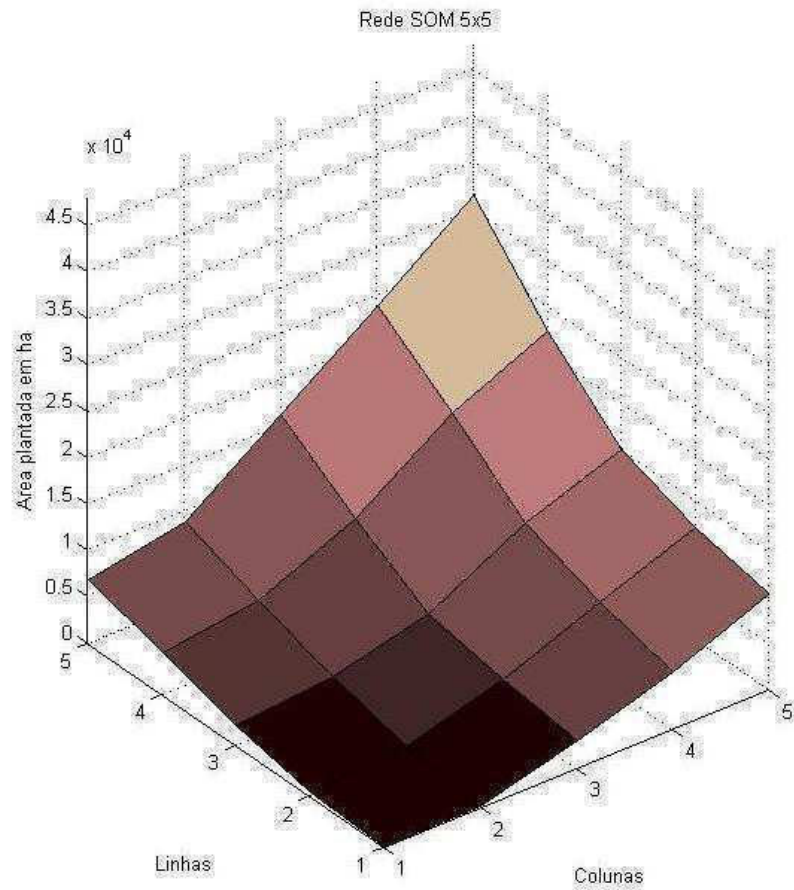
Quadro 11: Relação grupo, centróide e quantitativo de municípios classificados em 1995 e 2010.

Grupos (classes)	Centróides/Pesos (ha)	Quantitativo Municípios Classificados (ano 1995)	Quantitativo Municípios Classificados (ano 2010)
0	59	196	150
1	191	18	17
2	3103	2	5
3	6191	4	3
4	10364	9	1
5	434	2	9
6	1142	1	14
7	4115	1	2
8	8331	9	1
9	12133	1	5
10	2111	1	6
11	3118	1	6
12	5673	1	1
13	11341	-	2
14	15118	-	1
15	4483	-	5
16	5786	-	0
17	10402	-	3
18	17707	-	3
19	22285	-	5
20	6862	-	3
21	8820	-	1
22	16288	-	0
23	23689	-	1
24	31536	-	2

Fonte: Autor (2013).

Ao considerar uma rede artificial com dimensão 5 x 5, observa-se uma configuração tridimensional, representada pela Figura 19.


Figura 19: Comportamento relativo à área plantada de cana-de-açúcar.



Fonte: Autor (2013).

Com base na representação da rede, é necessário explicar que cada centroide ou peso determinou o agrupamento dos municípios pertencentes a um mesmo grupo, considerando o índice de produção de cada município. Nesse sentido, a posição do grupo na rede apresenta distribuição sequencial de 0 a 24, conforme apresentado na Figura 20:

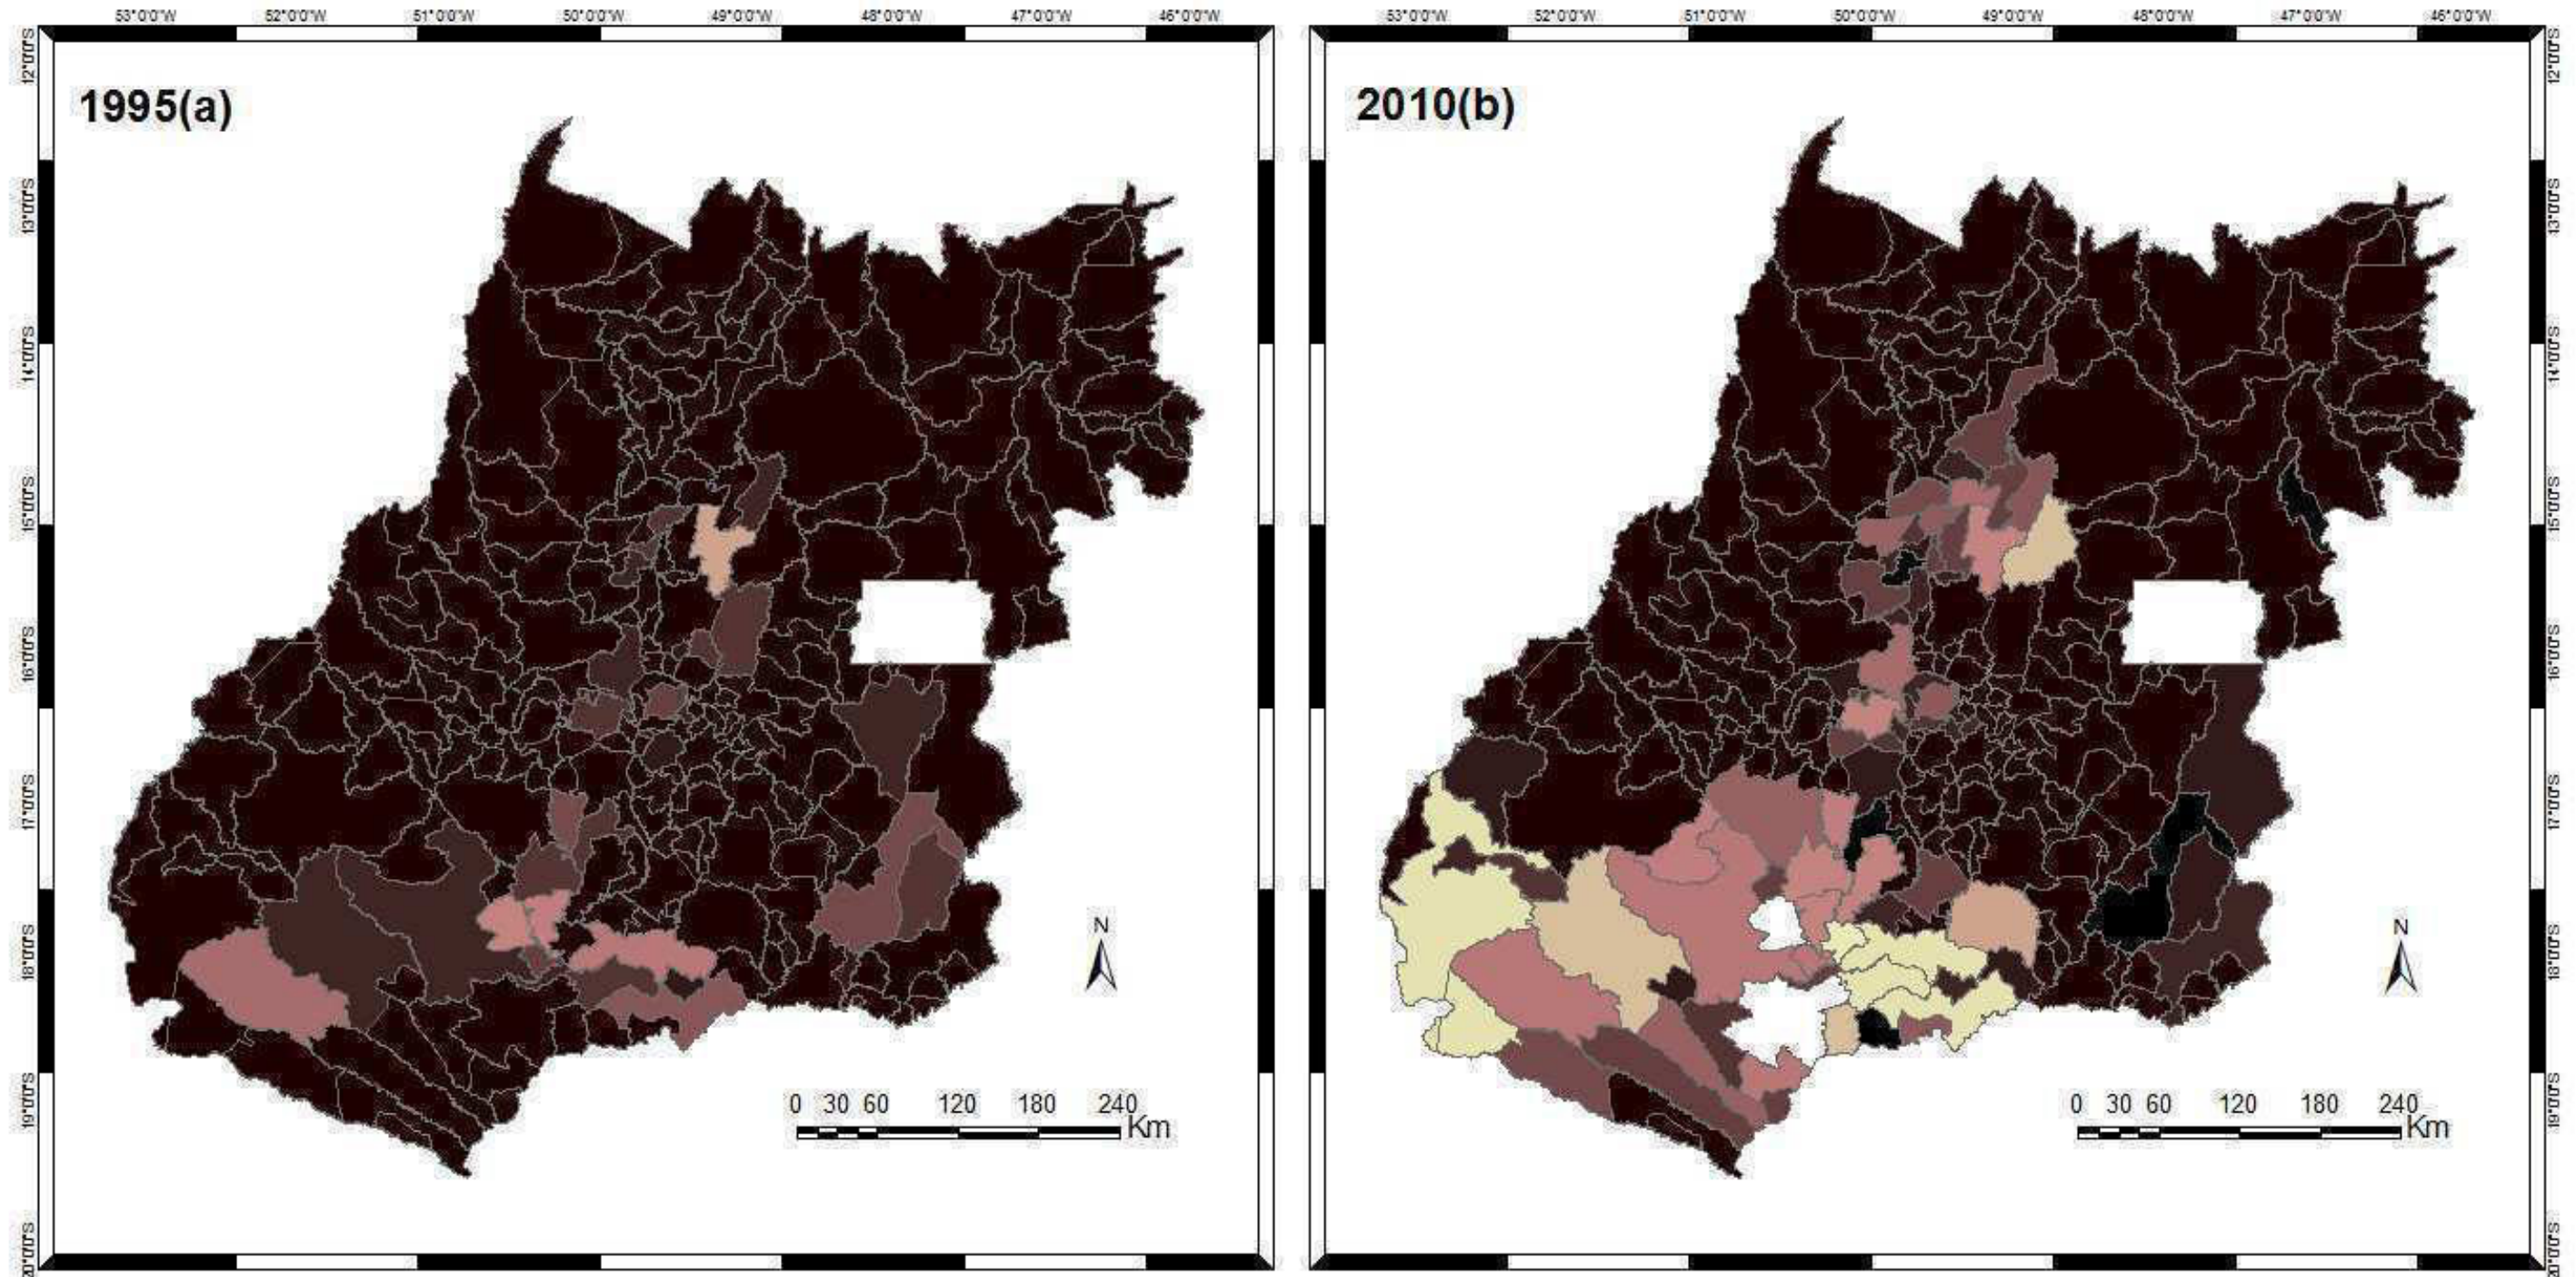
Figura 20: Legenda de cor relacionada ao mapa de classificação temporal (Figura 21).



Fonte: Autor (2013).

A classificação realizada para a área plantada de cana-de-açúcar, indicada na Figura 21, mostra que os municípios representados com a mesma cor foram agrupados por um mesmo centroide. A legenda acima, que indica os grupos nos quais os municípios foram classificados, é interpretada levando-se em consideração a linha e a coluna onde o neurônio está localizado. Por exemplo: o grupo 16 foi classificado por um neurônio que está disposto na linha 3 e coluna 1; o grupo 8 foi classificado por um neurônio localizado na linha 1 e coluna 3 e, assim, sucessivamente. É importante ressaltar que as cores representadas na Figura 21 são correspondentes ao grupo no qual o município está classificado (Figura 20).

CLASSIFICAÇÃO DA ÁREA PLANTADA DE CANA-DE-AÇÚCAR (ha) NO ESTADO DE GOIÁS



INFORMAÇÕES CARTOGRÁFICAS

Projeção Universal Transversa de Mercator - UTM

Datum horizontal: SAD - 69

Datum vertical: Imbituba-SC

Origem da quilometragem: Equador e Meridiano 51°W.Gr.

Fonte: Base Cartográfica Digital (SIEG)

Dados de Área Plantada de Cana - IBGE (2012)























































Figura 21: Classificação da área plantada de cana-de-açúcar no Estado de Goiás, com a utilização de rede neural artificial de Kohonen com dimensão 5x5.

(a) Ano de 1995.(b) Ano de 2010.

Autores: CAMPOS, Eude S.
PEREIRA, Natasha S.

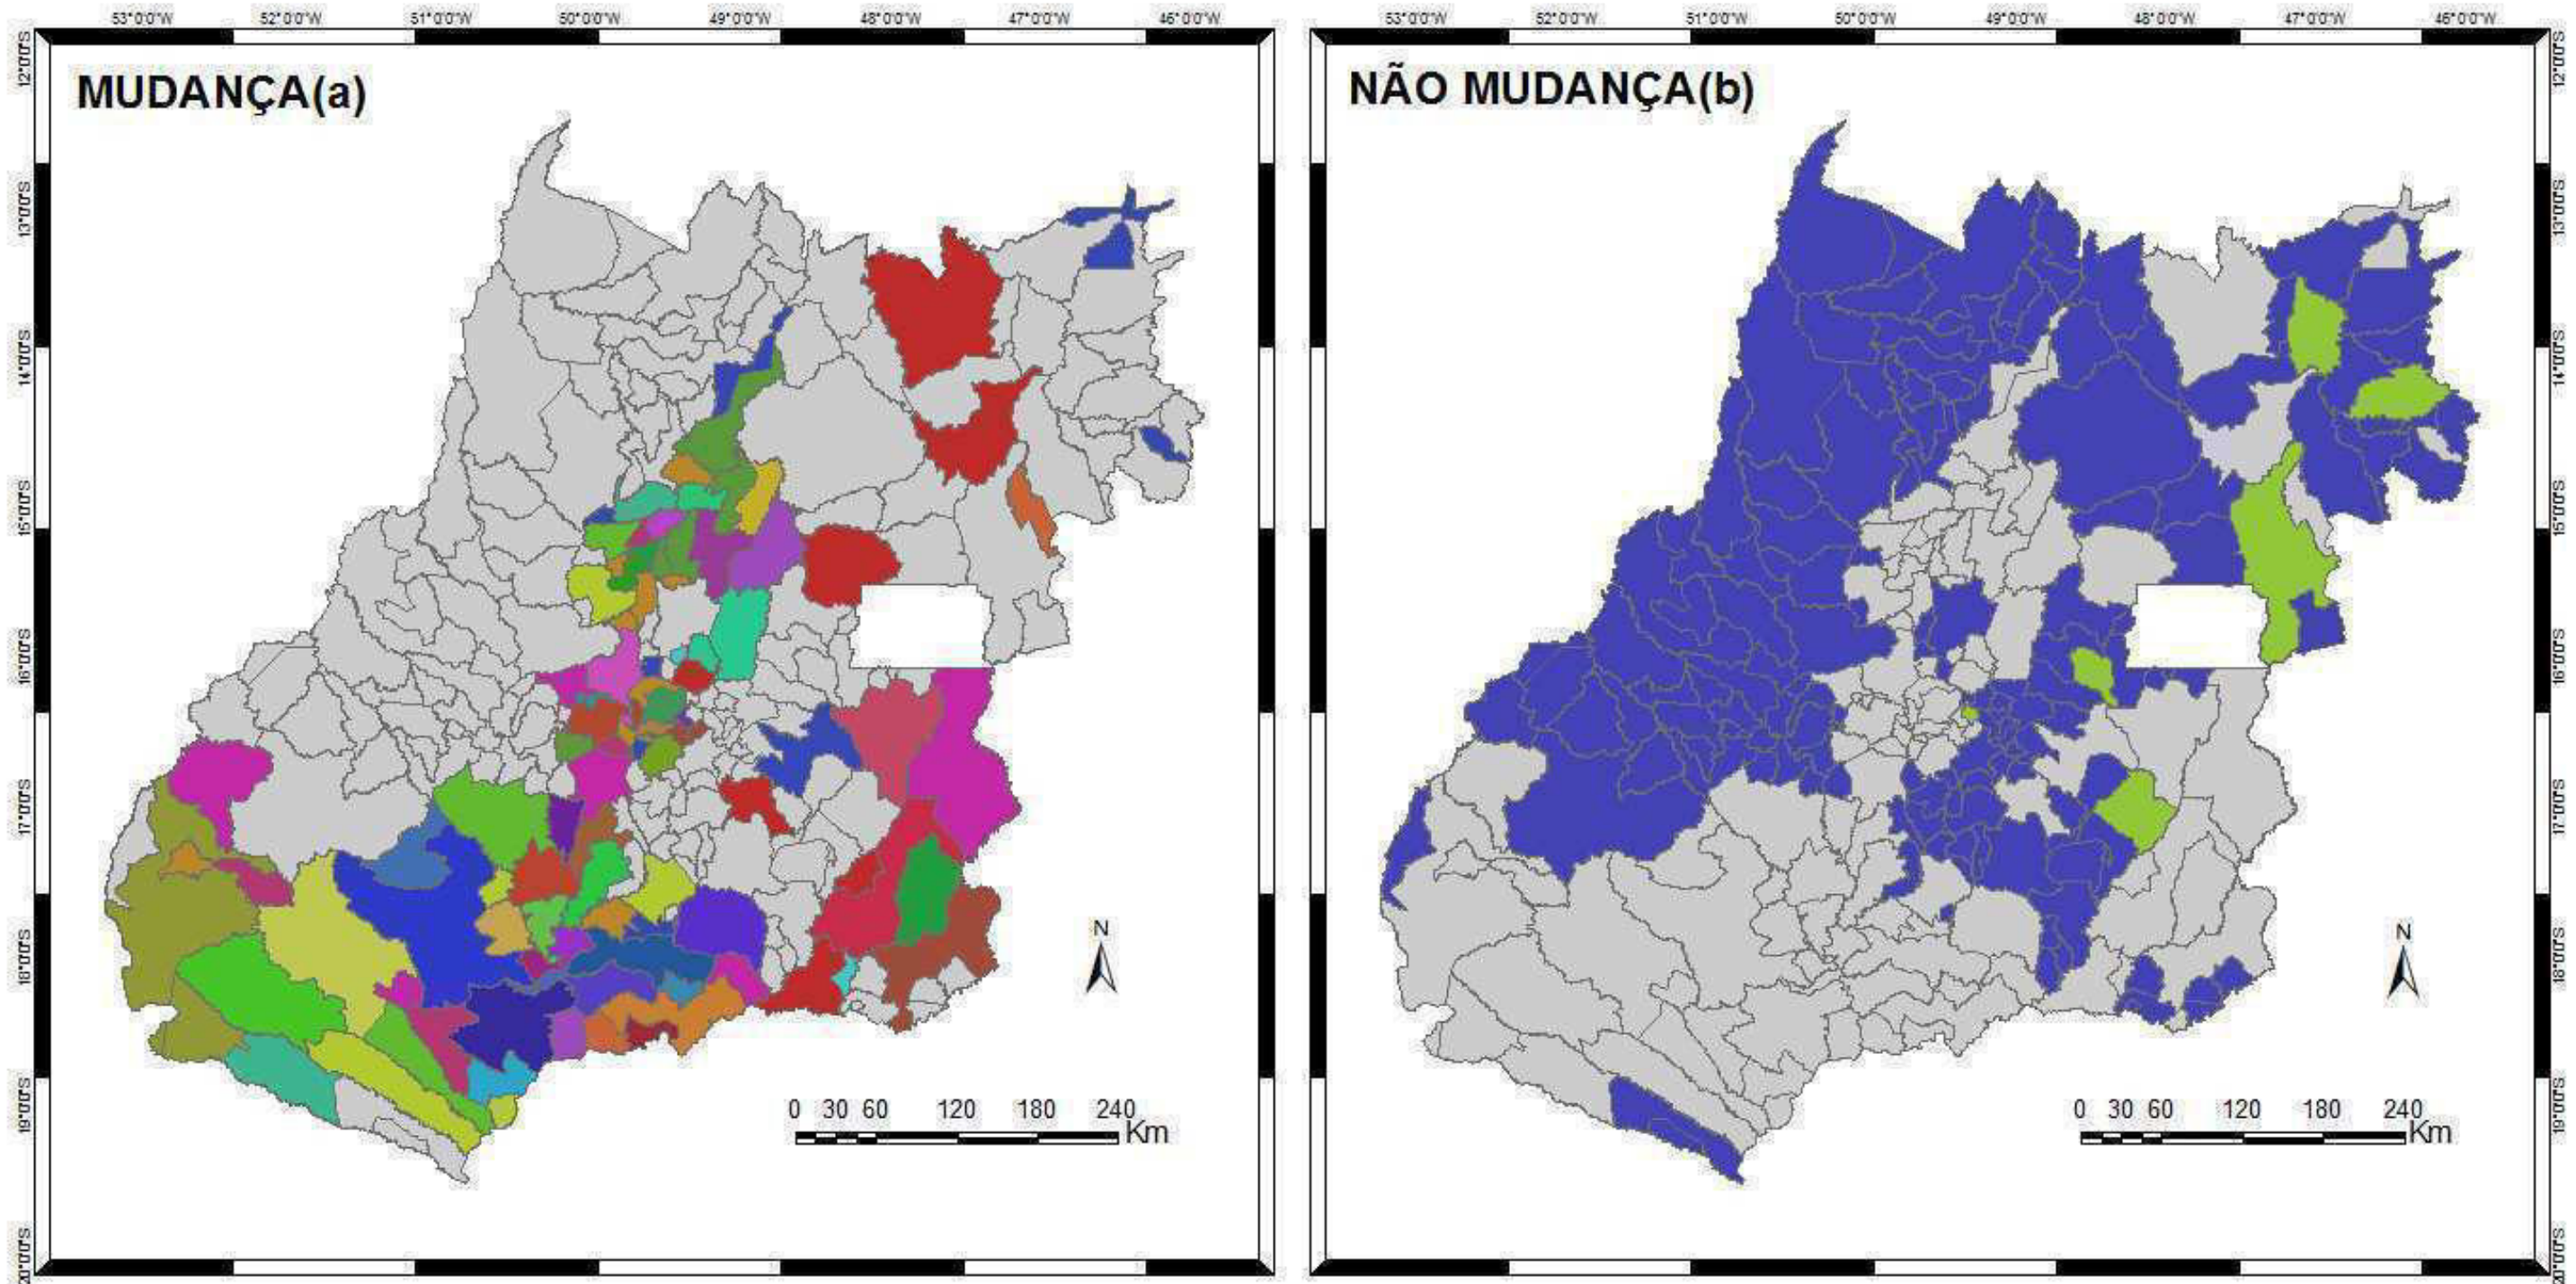
A detecção de mudanças foi realizada levando-se em consideração os dois tempos simultâneos (1995 e 2010), representados pela Figura 23. Todas as cores, exceto a cinza, representadas no mapa (a) da Figura 23 indicam as mudanças descritas conforme a Figura 22 (mudança). As cores, exceto a cinza, no mapa (b) da Figura 23 indicam as não mudanças de grupos conforme a Figura 22 (não mudança). A cor cinza indica, no mapa de mudança (a), os municípios em que não ocorreu mudança (NC) do perfil produtivo. No mapa de não mudança (b) a cor cinza representa os municípios em que ocorreram mudanças (C) do perfil produtivo.

Figura 22: Legenda correspondente aos mapas de mudança e não mudança (Figura 23).

MUDANÇA							NÃO MUDANÇA		
 NC	 C:0->10	 C:0->23	 C:5->6	 C:6->18	 C:10->15	 C	 NC:0	 NC:1	
 C:0->1	 C:0->11	 C:0->24	 C:6->1	 C:7->13	 C:10->19				
 C:0->2	 C:0->13	 C:1->0	 C:6->5	 C:7->15	 C:12->19				
 C:0->3	 C:0->14	 C:1->6	 C:6->8	 C:8->17	 C:13->9				
 C:0->4	 C:0->15	 C:1->10	 C:6->10	 C:9->24	 C:14->9				
 C:0->5	 C:0->18	 C:2->3	 C:6->11	 C:10->0	 C:17->19				
 C:0->6	 C:0->19	 C:2->17	 C:6->12	 C:10->3					
 C:0->7	 C:0->20	 C:5->0	 C:6->15	 C:10->5					
 C:0->9	 C:0->21	 C:5->1	 C:6->17	 C:10->9					

Fonte: Autor (2013).

DETECÇÃO DE MUDANÇAS DA ÁREA PLANTADA DE CANA-DE-AÇÚCAR (ha) NO ESTADO DE GOIÁS



INFORMAÇÕES CARTOGRÁFICAS

Projeção Universal Transversa de Mercator - UTM

Datum horizontal: SAD - 69

Datum vertical: Imbituba-SC

Origem da quilometragem: Equador e Meridiano 51°W.Gr.

Fonte: Base Cartográfica Digital (SIEG)

Dados de Área Plantada de Cana - IBGE (2012)

Figura 23: Detecção de mudanças da área plantada de cana-de-açúcar no Estado de Goiás, com a utilização de rede neural artificial de Kohonen com dimensão 5X5.
(a) Mapa de Mudança.(b) Mapa de Não Mudança.

Quadro 12: Análise de mudança da produção para os municípios goianos

Grupos	Centróide (ha)	Nº de Municípios	Cenário de Produção Apresentado
0 → 0	59	139	inalterado
1 → 1	191	6	inalterado
0 → 1	59 → 191	9	crecente
0 → 2	59 → 3103	5	crecente
0 → 3	59 → 6191	1	crecente
0 → 4	59 → 10364	1	crecente
0 → 5	59 → 434	6	crecente
0 → 6	59 → 1142	9	crecente
0 → 7	59 → 4115	2	crecente
0 → 9	59 → 12133	1	crecente
0 → 10	59 → 2111	4	crecente
0 → 11	59 → 3118	5	crecente
0 → 13	59 → 11342	1	crecente
0 → 14	59 → 15119	1	crecente
0 → 15	59 → 4483	2	crecente
0 → 18	59 → 17707	2	crecente
0 → 19	59 → 22285	2	crecente
0 → 20	59 → 6862	3	crecente
0 → 21	59 → 8820	1	crecente
0 → 23	59 → 23690	1	crecente
0 → 24	59 → 31536	1	crecente
1 → 0	191 → 59	7	decrecente
1 → 6	191 → 1142	4	crecente
1 → 10	191 → 2111	1	crecente
2 → 3	3103 → 6191	1	crecente
2 → 17	3103 → 10402	1	crecente
5 → 0	434 → 59	2	decrecente
5 → 1	434 → 191	1	decrecente
5 → 6	434 → 1142	1	crecente
6 → 1	1142 → 191	1	decrecente
6 → 5	1142 → 434	1	decrecente
6 → 8	1142 → 8331	1	crecente
6 → 10	1142 → 2111	1	crecente
6 → 11	1142 → 3118	1	crecente
6 → 12	1142 → 5673	1	crecente
6 → 15	1142 → 4483	1	crecente
6 → 17	1142 → 10402	1	crecente
6 → 18	1142 → 17707	1	crecente
7 → 13	4115 → 11342	1	crecente
7 → 15	4115 → 4483	1	crecente
8 → 17	8331 → 10402	1	crecente
9 → 24	12133 → 31536	1	crecente
10 → 0	2111 → 59	2	decrecente
10 → 3	2111 → 6191	1	crecente
10 → 5	2111 → 434	2	decrecente

10 → 9	2111 → 12133	2	crecente
10 → 15	2111 → 4483	1	crecente
10 → 19	2111 → 22285	1	crecente
12 → 19	5673 → 22285	1	crecente
13 → 9	11342 → 12133	1	crecente
14 → 9	15119 → 12133	1	decrecente
17 → 19	10402 → 22285	1	crecente

Fonte: Autor (2013). NC = 145 municípios; C = 101municípios.

Ao analisar o perfil da área plantada (em ha) para a cana-de-açúcar é possível perceber que, dos 246 municípios goianos, 101 (41%) deles sofreram mudanças de cenário e 145 (59%) permaneceram inalterados (destes, 139 são do grupo NC:0 (cerca de 59 ha de área plantada) e 6 são do grupo NC:1 (cerca de 191 ha de área plantada)). As não mudanças (grupos NC) ocorreram com os municípios das regiões norte, noroeste, oeste e nordeste goiano, enquanto que as mudanças (grupos C) ocorrem no sudoeste, sul, centro, sudeste goiano e parte do entorno do Distrito Federal (ver Figura 7). Consta-se ainda que, dos 101 municípios, 84 (83%) tiveram acréscimo da área plantada. Apenas 17 (17%) municípios decresceram a área de plantio. A análise da mudança da produção (Quadro 12) permite deduzir que 19 municípios possuíam pequena área plantada e tornaram-se grandes produtores, isto é, com área de plantio acima de 10.000 hectares. Outra análise que pode ser feita diz respeito aos 62 municípios considerados pequenos produtores que elevaram a área de plantio e continuaram com baixa produção. Em última análise é possível constatar que 3 municípios (Goiatuba, Santa Helena de Goiás e Turvelândia) já considerados grandes produtores aumentaram ainda mais a área de plantio da cana-de-açúcar.

De acordo com o Instituto Mauro Borges de Estatísticas e Estudos Socioeconômicos (IMB) da Secretaria de Gestão e Planejamento (SEGPLAN), no ano de 2010, o Produto Interno Bruto (PIB) de Goiás atingiu a cifra de R\$ 97,576 bilhões, com crescimento de 8,8%. O cultivo da cana-de-açúcar contribuiu de forma significativa para o crescimento da economia goiana (+10%) (SEGPLAN, 2012). Logo, é justificável o comportamento de crescimento e expansão do cultivo da cana nos municípios goianos, pois a rentabilidade e o incremento da atividade econômica com a cultura canavieira apresenta uma conjuntura de cenário otimista e lucrativa não só para Goiás como para os Estados das Regiões Centro-Oeste e Sudeste do Brasil.

5.4.2 A Detecção de Mudanças para o Rebanho Bovino de Corte em Goiás

Para o rebanho bovino de corte foram definidos os pesos e os grupos conforme apresentados no quadro abaixo:


Quadro 13: Relação grupo, centróide e quantitativo de municípios classificados em 1995 e 2010.

Grupos (classes)	Centróides/Pesos (nº cabeças)	Quantitativo Municípios Classificados (ano 1995)	Quantitativo Municípios Classificados (ano 2010)
0	20356	69	61
1	33141	26	25
2	54480	12	18
3	120062	8	3
4	151838	17	2
5	38436	24	5
6	42192	2	18
7	56080	4	2
8	151849	8	11
9	200925	13	6
10	56917	13	10
11	56423	1	0
12	76717	3	24
13	235540	8	2
14	296722	11	4
15	86831	4	12
16	101403	2	11
17	202298	2	5
18	333984	5	3
19	387401	6	3
20	123410	4	10
21	145420	2	5
22	263122	2	4
23	385642	-	0
24	486861	-	2

Fonte: Autor (2013).

Ao considerar uma rede artificial com dimensão 5 x 5, observa-se uma configuração tridimensional, representada pela Figura 24:


Figura 24: Comportamento relativo ao rebanho bovino de corte.



Fonte: Autor (2013).

Com base na representação da rede, é necessário explicar que cada centroide ou peso determinou o agrupamento dos municípios pertencentes a um mesmo grupo, considerando o índice de produção de cada município. Nesse sentido, a posição do grupo na rede apresenta distribuição sequencial de 0 a 24, conforme apresentado na Figura 25:

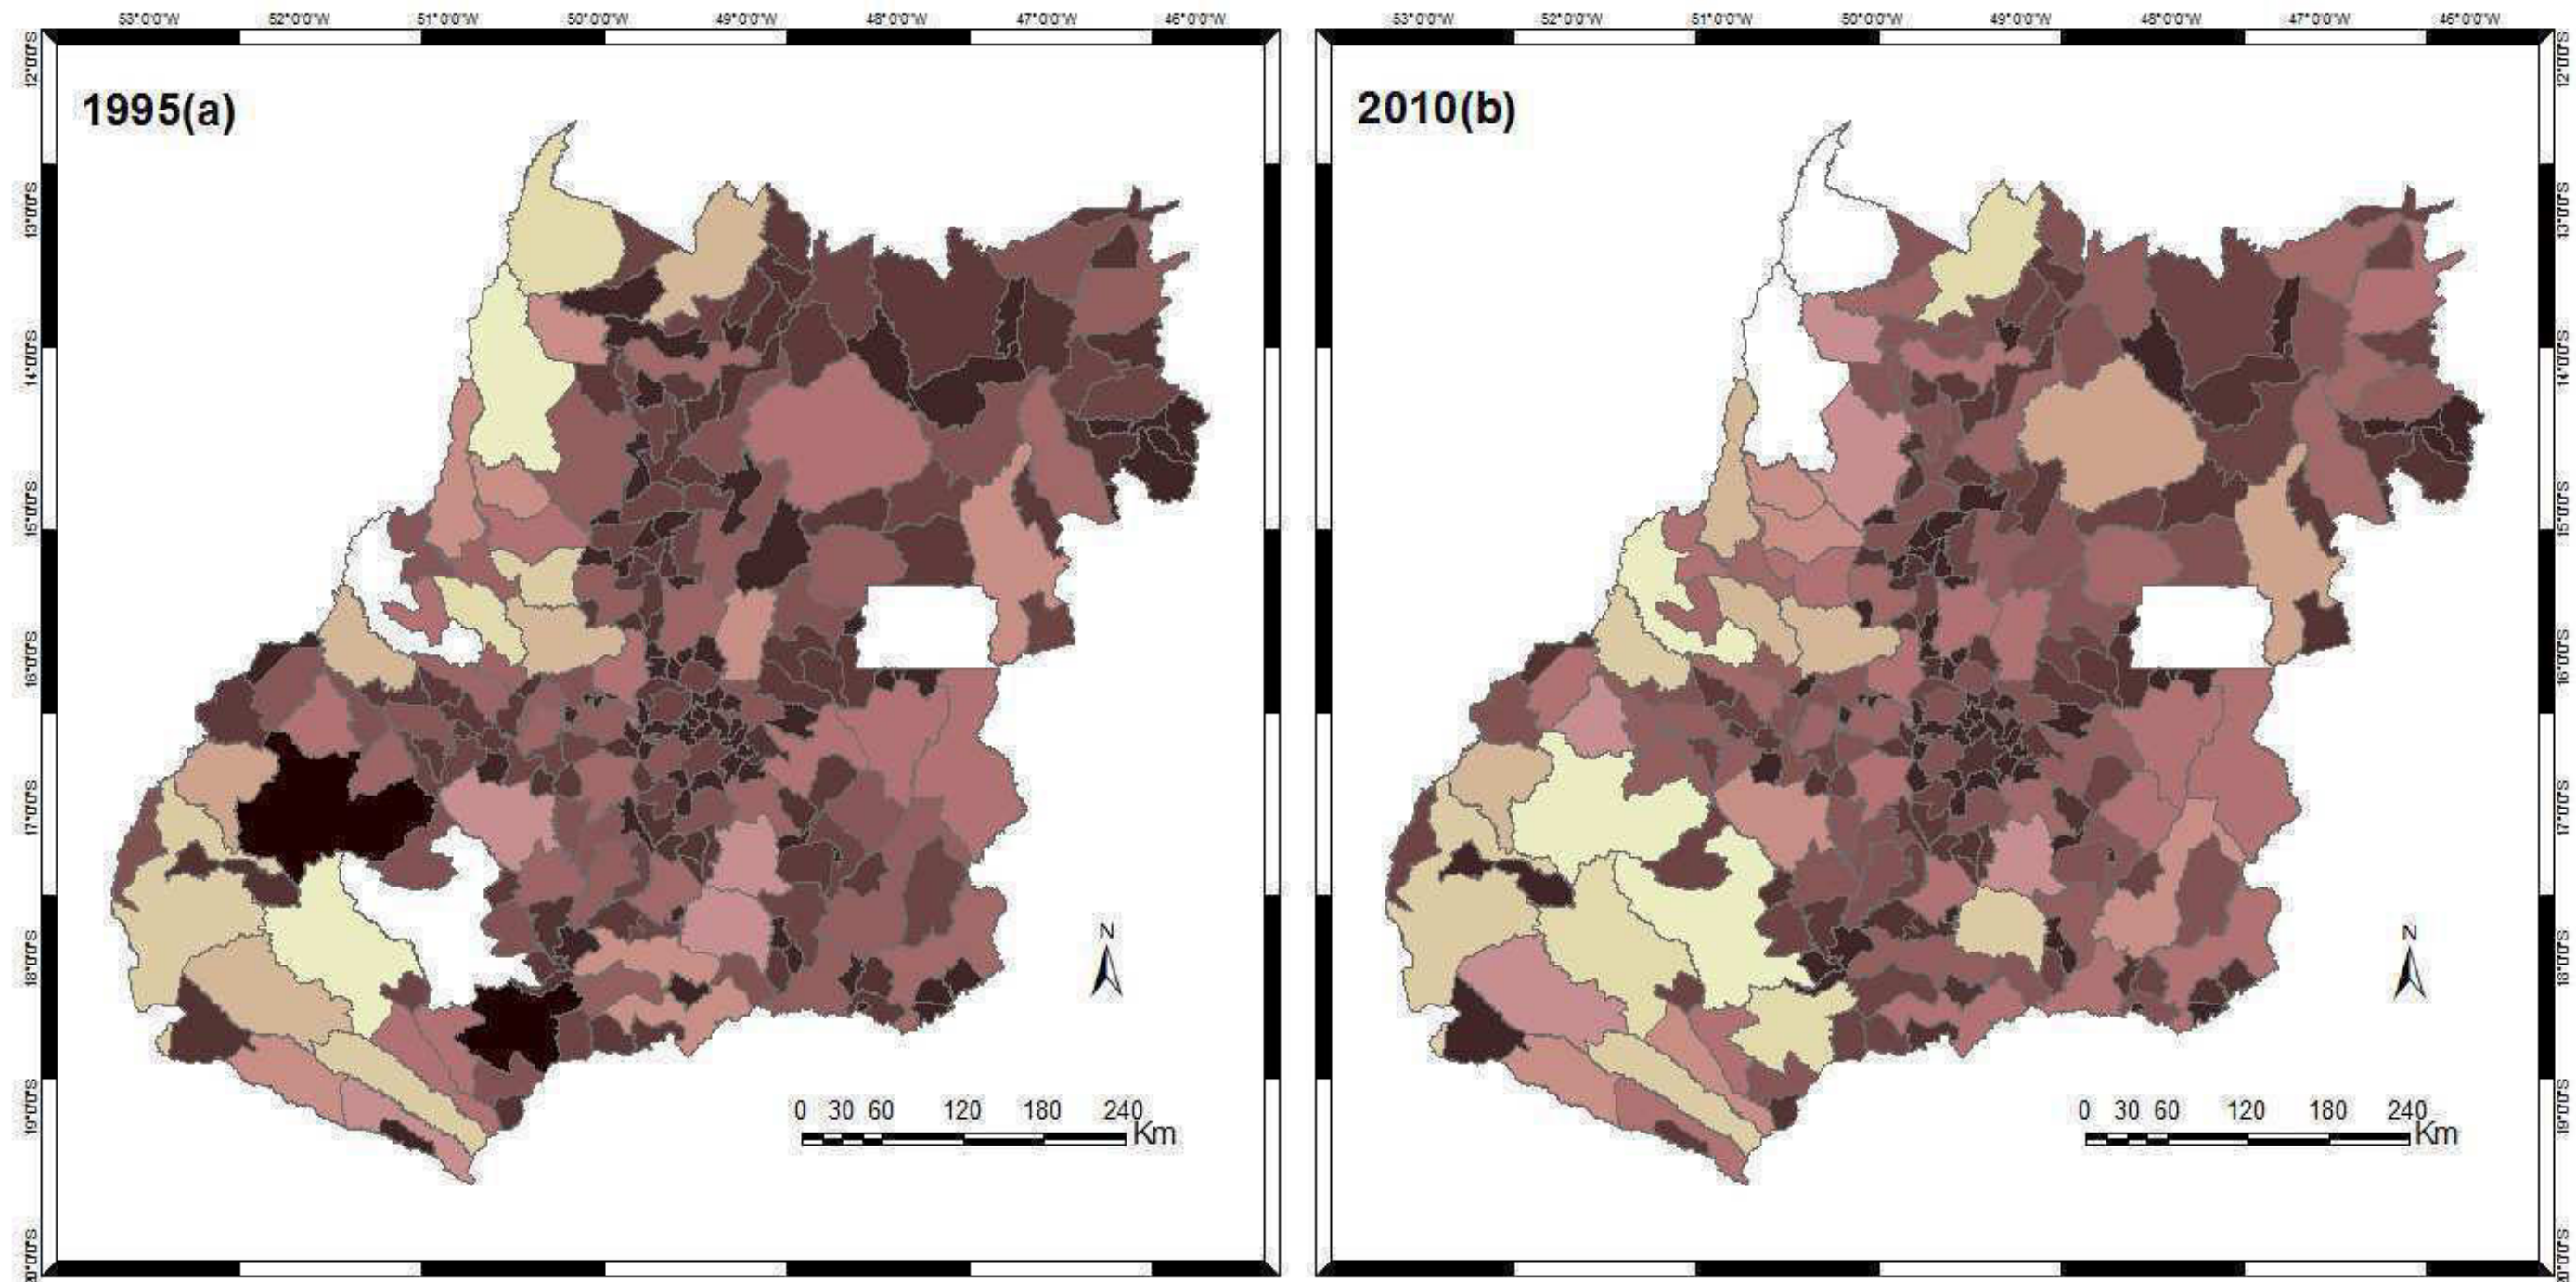
Figura 25: Legenda de cor relacionada ao mapa de classificação temporal (Figura 26).



Fonte: Autor (2013).

A classificação realizada para o rebanho bovino de corte, indicada na Figura 26, mostra que os municípios representados com a mesma cor foram agrupados por um mesmo centroide. A Figura 25, que indica os grupos nos quais os municípios foram classificados, é interpretada levando-se em consideração a linha e a coluna onde o neurônio está localizado. Por exemplo: o grupo 7 foi classificado por um neurônio que está disposto na linha 1 e coluna 2; o grupo 15 foi classificado por um neurônio localizado na linha 3 e coluna 0 e, assim, sucessivamente. É importante ressaltar que as cores representadas na Figura 26 são correspondentes ao grupo no qual o município está classificado (Figura 25).

CLASSIFICAÇÃO DO REBANHO BOVINO DE CORTE NO ESTADO DE GOIÁS



INFORMAÇÕES CARTOGRÁFICAS

Projeção Universal Transversa de Mercator - UTM

Datum horizontal: SAD - 69

Datum vertical: Imbituba-SC

Origem da quilometragem: Equador e Meridiano 51°W.Gr.

Fonte: Base Cartográfica Digital (SIEG)

Dados de Área Plantada de Cana - IBGE (2012)

Figura 26: Classificação do rebanho de corte no Estado de Goiás, com a utilização de rede neural artificial de Kohonen com dimensão 5X5.
(a) Ano de 1995.(b) Ano de 2010.

Autores: CAMPOS, Eude S.
PEREIRA, Natasha S.

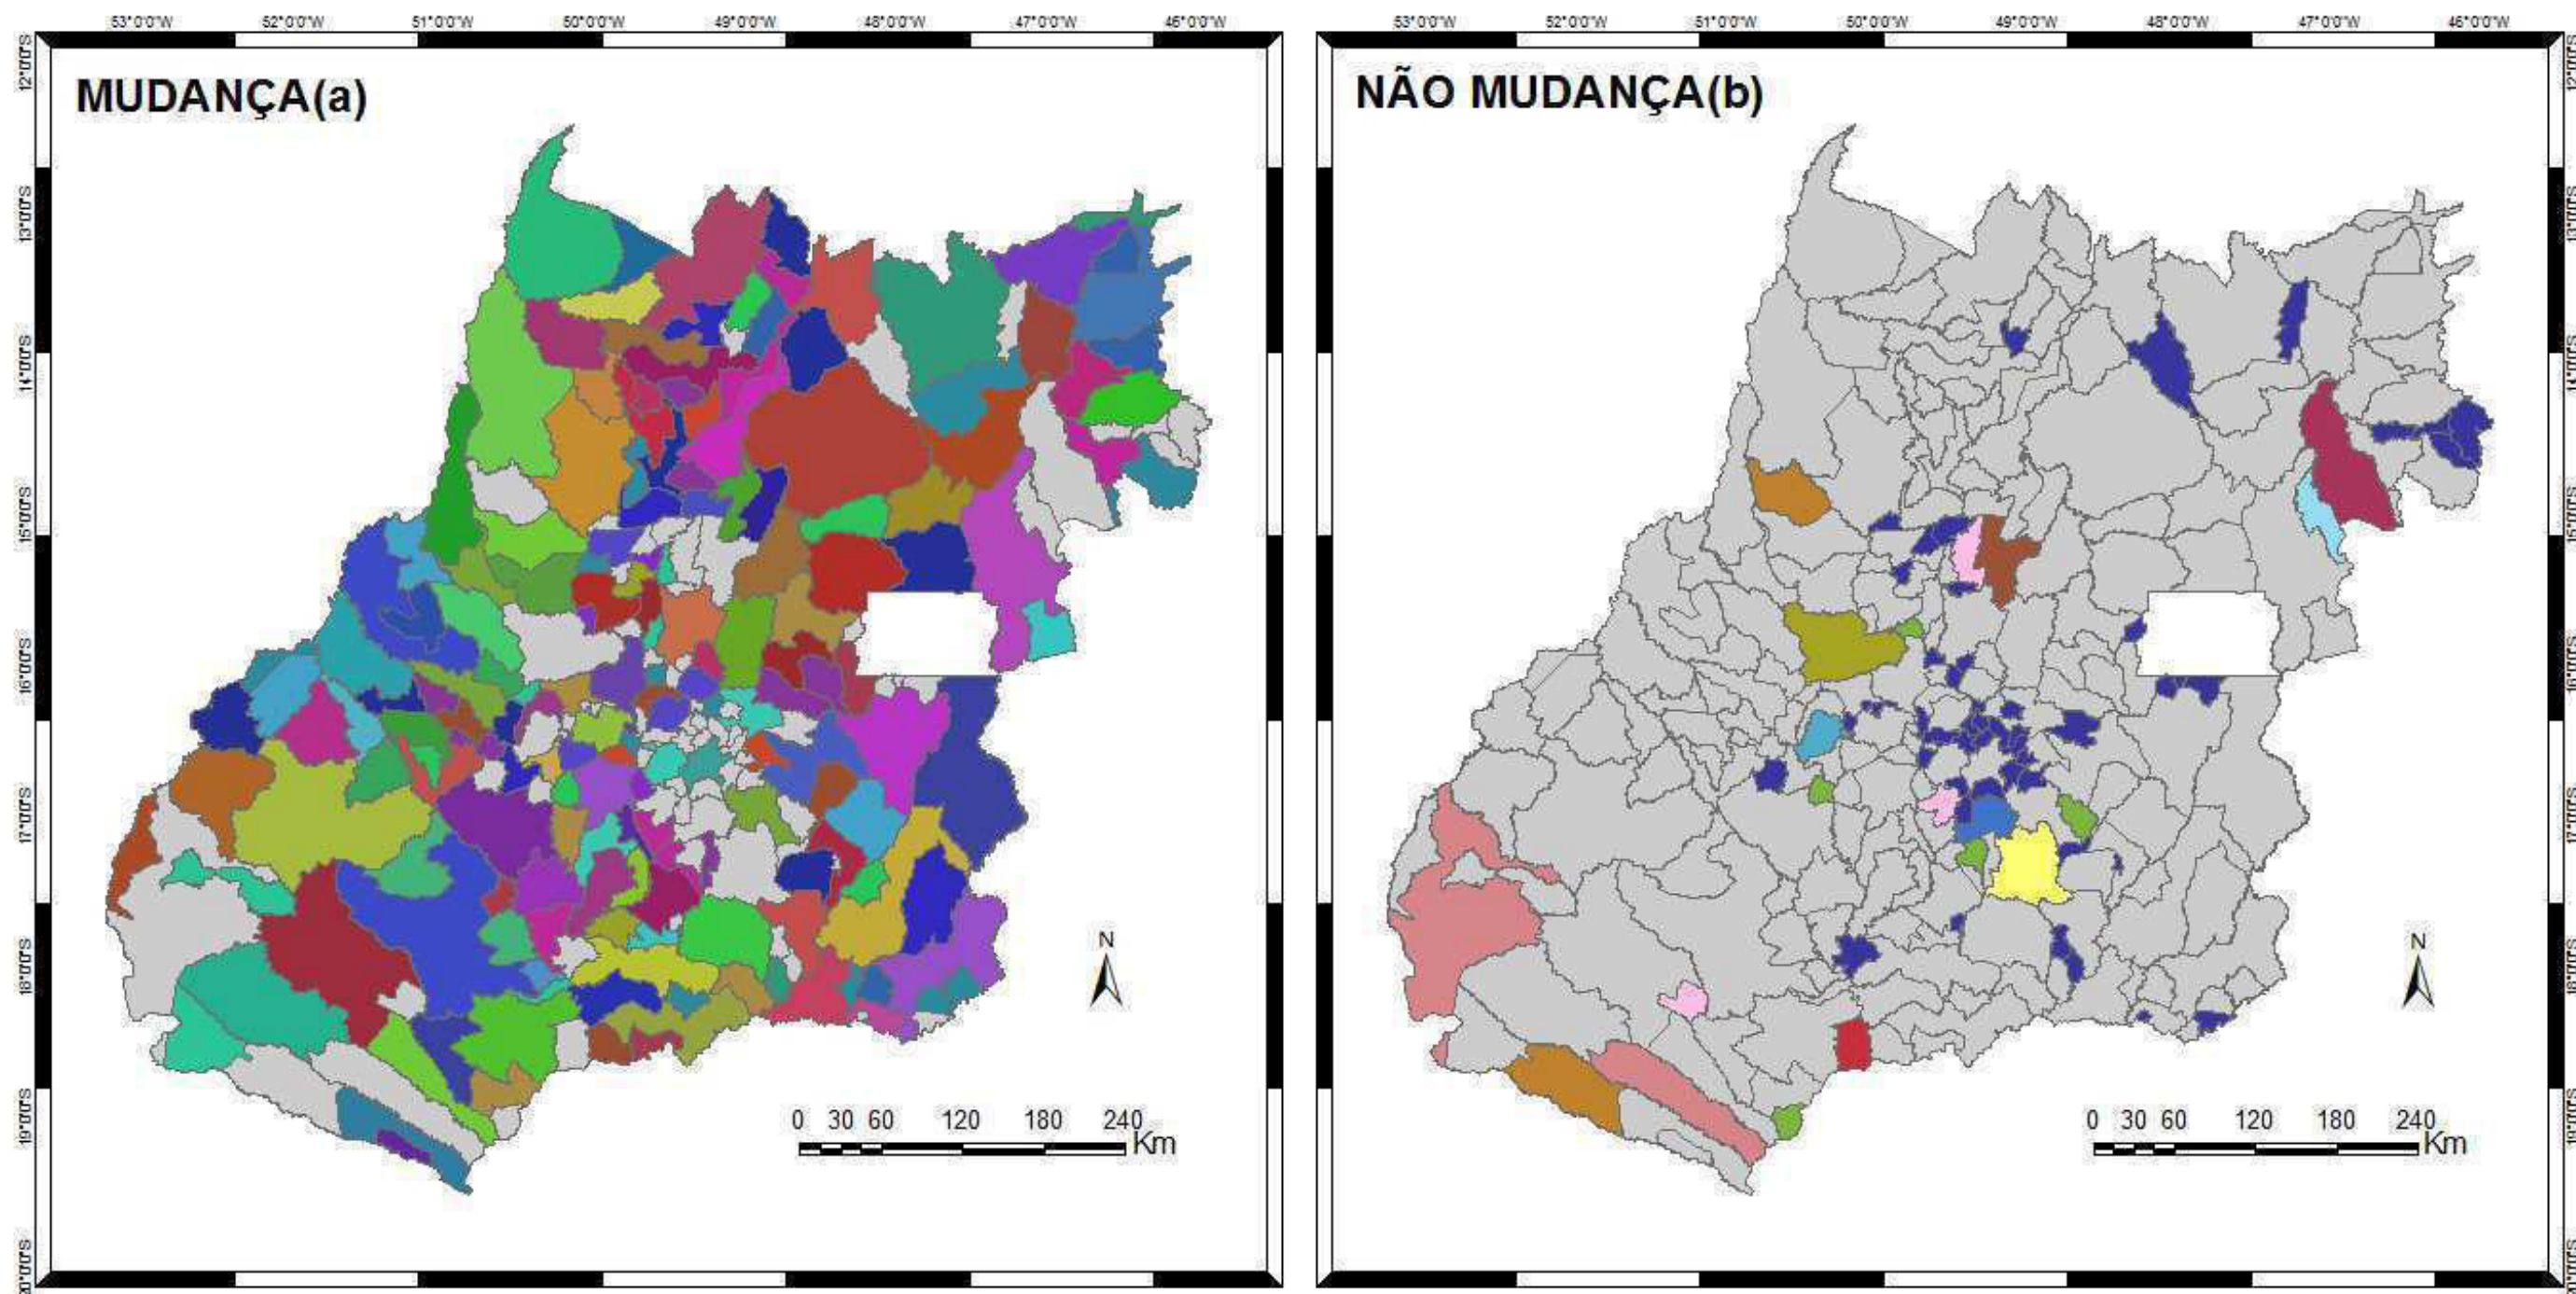
A detecção de mudanças foi realizada levando-se em consideração os dois tempos simultâneos (1995 e 2010), representados pela Figura 28. Todas as cores, exceto a cinza, representadas no mapa (a) da Figura 28 indicam as mudanças descritas conforme a Figura 27 (mudança). As cores, exceto a cinza, no mapa (b) da Figura 28 indicam as não mudanças de grupos conforme a figura 27 (não mudança). A cor cinza indica, no mapa de mudança (a), os municípios em que não ocorreu mudança (NC) do perfil produtivo. No mapa de não mudança (b) a cor cinza representa os municípios em que ocorreram mudanças (C) do perfil produtivo.

Figura 27: Legenda correspondente aos mapas de mudança e não mudança (Figura 28).

MUDANÇA							NÃO MUDANÇA			
NC	C:2->10	C:6->2	C:9->22	C:15->8	C:18->24	C	NC:10			
C:0->1	C:2->12	C:6->7	C:10->1	C:15->12	C:19->18	NC:0	NC:12			
C:0->2	C:2->15	C:6->10	C:10->12	C:15->16	C:19->24	NC:1	NC:14			
C:0->5	C:2->16	C:6->12	C:10->15	C:16->3	C:20->8	NC:2	NC:16			
C:0->6	C:3->8	C:6->15	C:10->16	C:16->8	C:20->21	NC:3	NC:17			
C:0->15	C:3->15	C:7->2	C:10->20	C:16->9	C:21->4	NC:6	NC:20			
C:0->20	C:3->16	C:7->15	C:12->2	C:16->10	C:21->8	NC:9	NC:22			
C:1->0	C:3->20	C:8->9	C:12->3	C:16->12	C:21->13					
C:1->2	C:5->0	C:8->20	C:12->10	C:16->17	C:21->16					
C:1->5	C:5->1	C:8->21	C:12->15	C:16->20	C:21->17					
C:1->6	C:5->2	C:9->8	C:12->16	C:16->21	C:22->14					
C:1->12	C:5->6	C:9->13	C:12->20	C:17->8	C:22->17					
C:2->0	C:5->12	C:9->16	C:13->22	C:17->9	C:22->18					
C:2->1	C:6->0	C:9->17	C:14->8	C:17->14	C:23->18					
C:2->6	C:6->1	C:9->21	C:15->6	C:18->22	C:23->19					
					C:24->19					

Fonte: Autor (2013).

DETECÇÃO DE MUDANÇAS DO REBANHO BOVINO DE CORTE NO ESTADO DE GOIÁS



INFORMAÇÕES CARTOGRÁFICAS

Projeção Universal Transversa de Mercator - UTM

Datum horizontal: SAD - 69

Datum vertical: Imbituba-SC

Origem da quilometragem: Equador e Meridiano 51°W.Gr.

Fonte: Base Cartográfica Digital (SIEG)

Dados de Área Plantada de Cana - IBGE (2012)

Figura 28: Detecção de mudanças do rebanho de corte no Estado de Goiás, com a utilização de rede neural artificial de Kohonen com dimensão 5X5.

(a) Mapa de Mudança.(b) Mapa de Não Mudança.

Autores: CAMPOS, Eude S.
PEREIRA, Natasha S.

Quadro 14: Análise de mudança da produção para os municípios goianos

Grupos	Centróide (nº cabeças)	Nº de Municípios	Cenário de Produção Apresentado
0 → 0	20356 → 20356	49	inalterado
1 → 1	33141 → 33141	5	inalterado
2 → 2	54480 → 54480	1	inalterado
3 → 3	120062 → 120062	1	inalterado
6 → 6	42192 → 42192	1	inalterado
9 → 9	200925 → 200925	2	inalterado
10 → 10	56917 → 56917	3	inalterado
12 → 12	76717 → 76717	1	inalterado
14 → 14	296722 → 296722	2	inalterado
16 → 16	101403 → 101403	1	inalterado
17 → 17	202298 → 202298	1	inalterado
20 → 20	123410 → 123410	1	inalterado
22 → 22	263122 → 263122	1	inalterado
0 → 1	20356 → 33141	12	crescente
0 → 2	20356 → 54480	1	crescente
0 → 5	20356 → 38436	2	crescente
0 → 6	20356 → 42192	2	crescente
0 → 15	20356 → 86831	2	crescente
0 → 20	20356 → 123410	1	crescente
1 → 0	33141 → 20356	7	decrésciente
1 → 2	33141 → 54480	4	crescente
1 → 5	33141 → 38436	3	crescente
1 → 6	33141 → 42192	6	crescente
1 → 12	33141 → 76717	1	crescente
2 → 0	54480 → 20356	1	decrésciente
2 → 1	54480 → 33141	2	decrésciente
2 → 6	54480 → 42192	1	decrésciente
2 → 10	54480 → 56917	1	crescente
2 → 12	54480 → 76717	4	crescente
2 → 15	54480 → 86831	1	crescente
2 → 16	54480 → 101403	1	crescente
3 → 8	120062 → 151849	1	crescente
3 → 15	120062 → 86831	1	decrésciente
3 → 16	120062 → 101403	2	decrésciente
3 → 20	120062 → 123410	3	crescente
5 → 0	38436 → 20356	1	decrésciente
5 → 1	38436 → 33141	3	decrésciente
5 → 2	38436 → 54480	5	crescente
5 → 6	38436 → 42192	7	crescente
5 → 12	38436 → 76717	1	crescente
6 → 0	42192 → 20356	3	decrésciente
6 → 1	42192 → 33141	2	decrésciente
6 → 2	42192 → 54480	4	crescente
6 → 7	42192 → 56080	2	crescente

6 → 10	42192 → 56917	3	crescente
6 → 12	42192 → 76717	8	crescente
6 → 15	42192 → 86831	1	crescente
7 → 2	56080 → 54880	1	decescente
7 → 15	56080 → 86831	1	crescente
8 → 9	151849 → 200925	2	crescente
8 → 20	151849 → 123410	1	decescente
8 → 21	151849 → 145420	1	decescente
9 → 8	200925 → 151849	1	decescente
9 → 13	200925 → 235540	1	crescente
9 → 16	200925 → 101403	1	decescente
9 → 17	200925 → 202298	1	crescente
9 → 21	200925 → 145420	1	decescente
9 → 22	200925 → 263122	1	crescente
10 → 1	56917 → 33141	1	decescente
10 → 12	56917 → 76717	4	crescente
10 → 15	56917 → 86831	1	crescente
10 → 16	56917 → 101403	3	crescente
10 → 20	56917 → 123410	1	crescente
12 → 2	76717 → 54480	2	decescente
12 → 3	76717 → 120062	1	crescente
12 → 10	76717 → 56917	2	decescente
12 → 15	76717 → 86831	5	crescente
12 → 16	76717 → 101403	1	crescente
12 → 20	76717 → 123410	1	crescente
13 → 22	235540 → 263122	1	crescente
14 → 8	296722 → 151849	1	decescente
15 → 6	86831 → 42192	1	decescente
15 → 8	86831 → 151849	3	crescente
15 → 12	86831 → 76717	3	decescente
15 → 16	86831 → 101403	1	crescente
16 → 3	101403 → 120062	1	crescente
16 → 8	101403 → 151849	1	crescente
16 → 9	101403 → 200925	1	crescente
16 → 10	101403 → 56917	1	decescente
16 → 12	101403 → 76717	2	decescente
16 → 17	101403 → 202298	1	crescente
16 → 20	101403 → 123410	2	crescente
16 → 21	101403 → 145420	1	crescente
17 → 8	202298 → 151849	1	decescente
17 → 9	202298 → 200925	1	decescente
17 → 14	202298 → 296722	1	crescente
18 → 22	333984 → 263122	1	decescente
18 → 24	333984 → 486861	1	crescente
19 → 18	387401 → 333984	1	decescente
19 → 24	387401 → 486861	1	crescente
20 → 8	333984 → 151849	2	decescente
20 → 21	333984 → 145420	2	decescente

21 → 4	145420 → 151838	2	crescente
21 → 8	145420 → 151849	1	crescente
21 → 13	145420 → 235540	1	crescente
21 → 16	145420 → 101403	1	decrésciente
21 → 17	145420 → 202298	1	crescente
22 → 14	263122 → 296722	1	crescente
22 → 17	263122 → 202298	1	decrésciente
22 → 18	263122 → 333984	1	crescente
23 → 18	385642 → 333984	1	decrésciente
23 → 19	385642 → 387401	1	crescente
24 → 19	486861 → 387401	2	decrésciente

Fonte: Autor (2013). NC = 69 municípios; C = 177 municípios.

Ao analisar o perfil do rebanho bovino de corte é possível perceber que, dos 246 municípios goianos, 177 (72%) sofreram mudanças de cenário e 69 (28%) permaneceram inalterados (destes, 49 são do grupo NC:0 (cerca de 20.356 cabeças), 5 do grupo NC:1 (cerca de 33.141 cabeças), 1 do grupo NC:2 (cerca de 54.480 cabeças), 1 do grupo NC:3 (cerca de 120.062 cabeças), 1 do grupo NC:6 (cerca de 42.192 cabeças), 2 do grupo NC:9 (cerca de 200.925 cabeças), 3 do grupo NC:10 (cerca de 56.917 cabeças), 1 do grupo NC:12 (cerca de 76717 cabeças), 2 do grupo NC:14 (cerca de 296.722 cabeças), 1 do grupo NC:16 (cerca de 101.403 cabeças), 1 do grupo NC:17 (cerca de 202.298 cabeças), 1 do grupo NC:20 (cerca de 333.984 cabeças) e 1 do grupo NC:22 (cerca de 263.122 cabeças). As não mudanças (grupos NC) ocorreram com alguns municípios das regiões sul, sudoeste, Metropolitana de Goiânia, noroeste, nordeste, centro goiano e Entorno do Distrito Federal, enquanto que as mudanças (Grupos C) ocorrem em todas as regiões do Estado de Goiás (ver Figura 7). Portanto, constata-se que dos 177 municípios com mudanças de cenário, 122 (69%) tiveram acréscimo no rebanho bovino. Enquanto 55 (31%) municípios decresceram o número de cabeças do rebanho bovino de corte.

Foi possível saber, por meio da análise da mudança de produção (Quadro 14), que 13 municípios que eram considerados pequenos produtores aumentaram o rebanho acima de 100.000 cabeças e tornaram-se grandes produtores. No perfil dos grandes produtores, há 21 municípios que mesmo com a diminuição do rebanho, o seu quantitativo de cabeças o mantiveram como grande produtor. Há 34 municípios que eram considerados pequenos produtores e reduziram o quantitativo do rebanho. Outra análise possível de ser feita refere-se a 28 municípios que eram considerados grandes produtores e aumentaram ainda mais o quantitativo do rebanho. Em uma última análise é possível constatar que 81 municípios goianos eram considerados pequenos produtores e, mesmo ampliando o rebanho permaneceram com o quantitativo de cabeças abaixo de 100.000, o que os

mantteve com perfil de pequenos produtores.

O Estado de Goiás, em 2010, mantinha-se entre os maiores produtores de rebanho bovino do Brasil, com 21,348 milhões de cabeças, o que representa 10,2% de participação (4º lugar no ranking nacional)(IBGE, 2010). A pecuária bovina de corte contribuiu de forma significativa para o crescimento da economia goiana (+14%)(SEGPLAN, 2012). Portanto, é justificável que mesmo diante do comportamento de crescimento e expansão do cultivo da cana-de-açúcar nos municípios goianos, os números para o rebanho são impressionantes e perfazem uma proporção de quase 4 bovinos por habitante, o que demonstra que a atividade continua sendo atrativa e rentável aos pecuaristas.

O cenário posto indica que nas regiões sul e sudoeste de Goiás onde a cana-de-açúcar sofreu vertiginosa expansão, o rebanho apresentou diminuição em quase todos os municípios. Logo, é possível afirmar que a cultura canavieira mostra-se como competidora em relação ao rebanho bovino em Goiás. Contudo, uma explicação pode ser dada para o fato de o quantitativo do rebanho, em termos gerais, continuar em crescimento. Conforme dados do censo agropecuário, disponibilizados pelo IBGE, na década de 1980, a taxa de lotação de pasto em Goiás era de 0,71 cabeça/hectare e, em 2006, essa taxa passou para mais de 1,01 cabeças por hectare (IBGE, 2012). Isso permite inferir que, com menor área de pasto para a pecuária, em razão da substituição pela lavoura de cana-de-açúcar, a alternativa foi aumentar a taxa de lotação de bovinos nos estabelecimentos. Esse processo manteve a estabilidade do rebanho e corrobora para que a pecuária se mantenha forte e lucrativa não só para o Estado de Goiás como para todos os Estados da Região Centro-Oeste do País.

5.4.3 A Detecção de Mudanças para a Produção Leiteira em Goiás

Para a produção leiteira em Goiás foram definidos os pesos e os grupos conforme apresentados no quadro abaixo:


Quadro 15: Relação grupo, centróide e quantitativo de municípios classificados em 1995 e 2010.

Grupos (classes)	Centróides/Pesos (em litros)	Quantitativo Municípios Classificados (ano 1995)	Quantitativo Municípios Classificados (ano 2010)
0	9586	4	6
1	11791	-	1
2	17072	4	11
3	29871	-	8
4	46748	4	13
5	7392	2	4
6	8507	3	6
7	11824	1	3
8	22061	5	14
9	32735	1	8
10	4606	20	12
11	5469	11	12
12	7859	4	12
13	13620	11	13
14	16034	5	6
15	2375	25	13
16	4046	22	23
17	6935	4	8
18	10481	4	5
19	11657	4	4
20	806	65	18
21	2573	23	17
22	6041	13	13
23	8598	8	10
24	9689	3	6

Fonte: Autor (2013).

Ao considerar uma rede artificial com dimensão 5 x 5, observa-se uma configuração tridimensional, representada pela Figura 29:


Figura 29: Comportamento relativo a produção leiteira.



Fonte: Autor (2013).

Com base na representação da rede, é necessário explicar que cada centroide ou peso determinou o agrupamento dos municípios pertencentes a um mesmo grupo, considerando o índice de produção de cada município. Nesse sentido, a posição do grupo na rede apresenta distribuição sequencial de 0 a 24, conforme apresentado na figura 30:

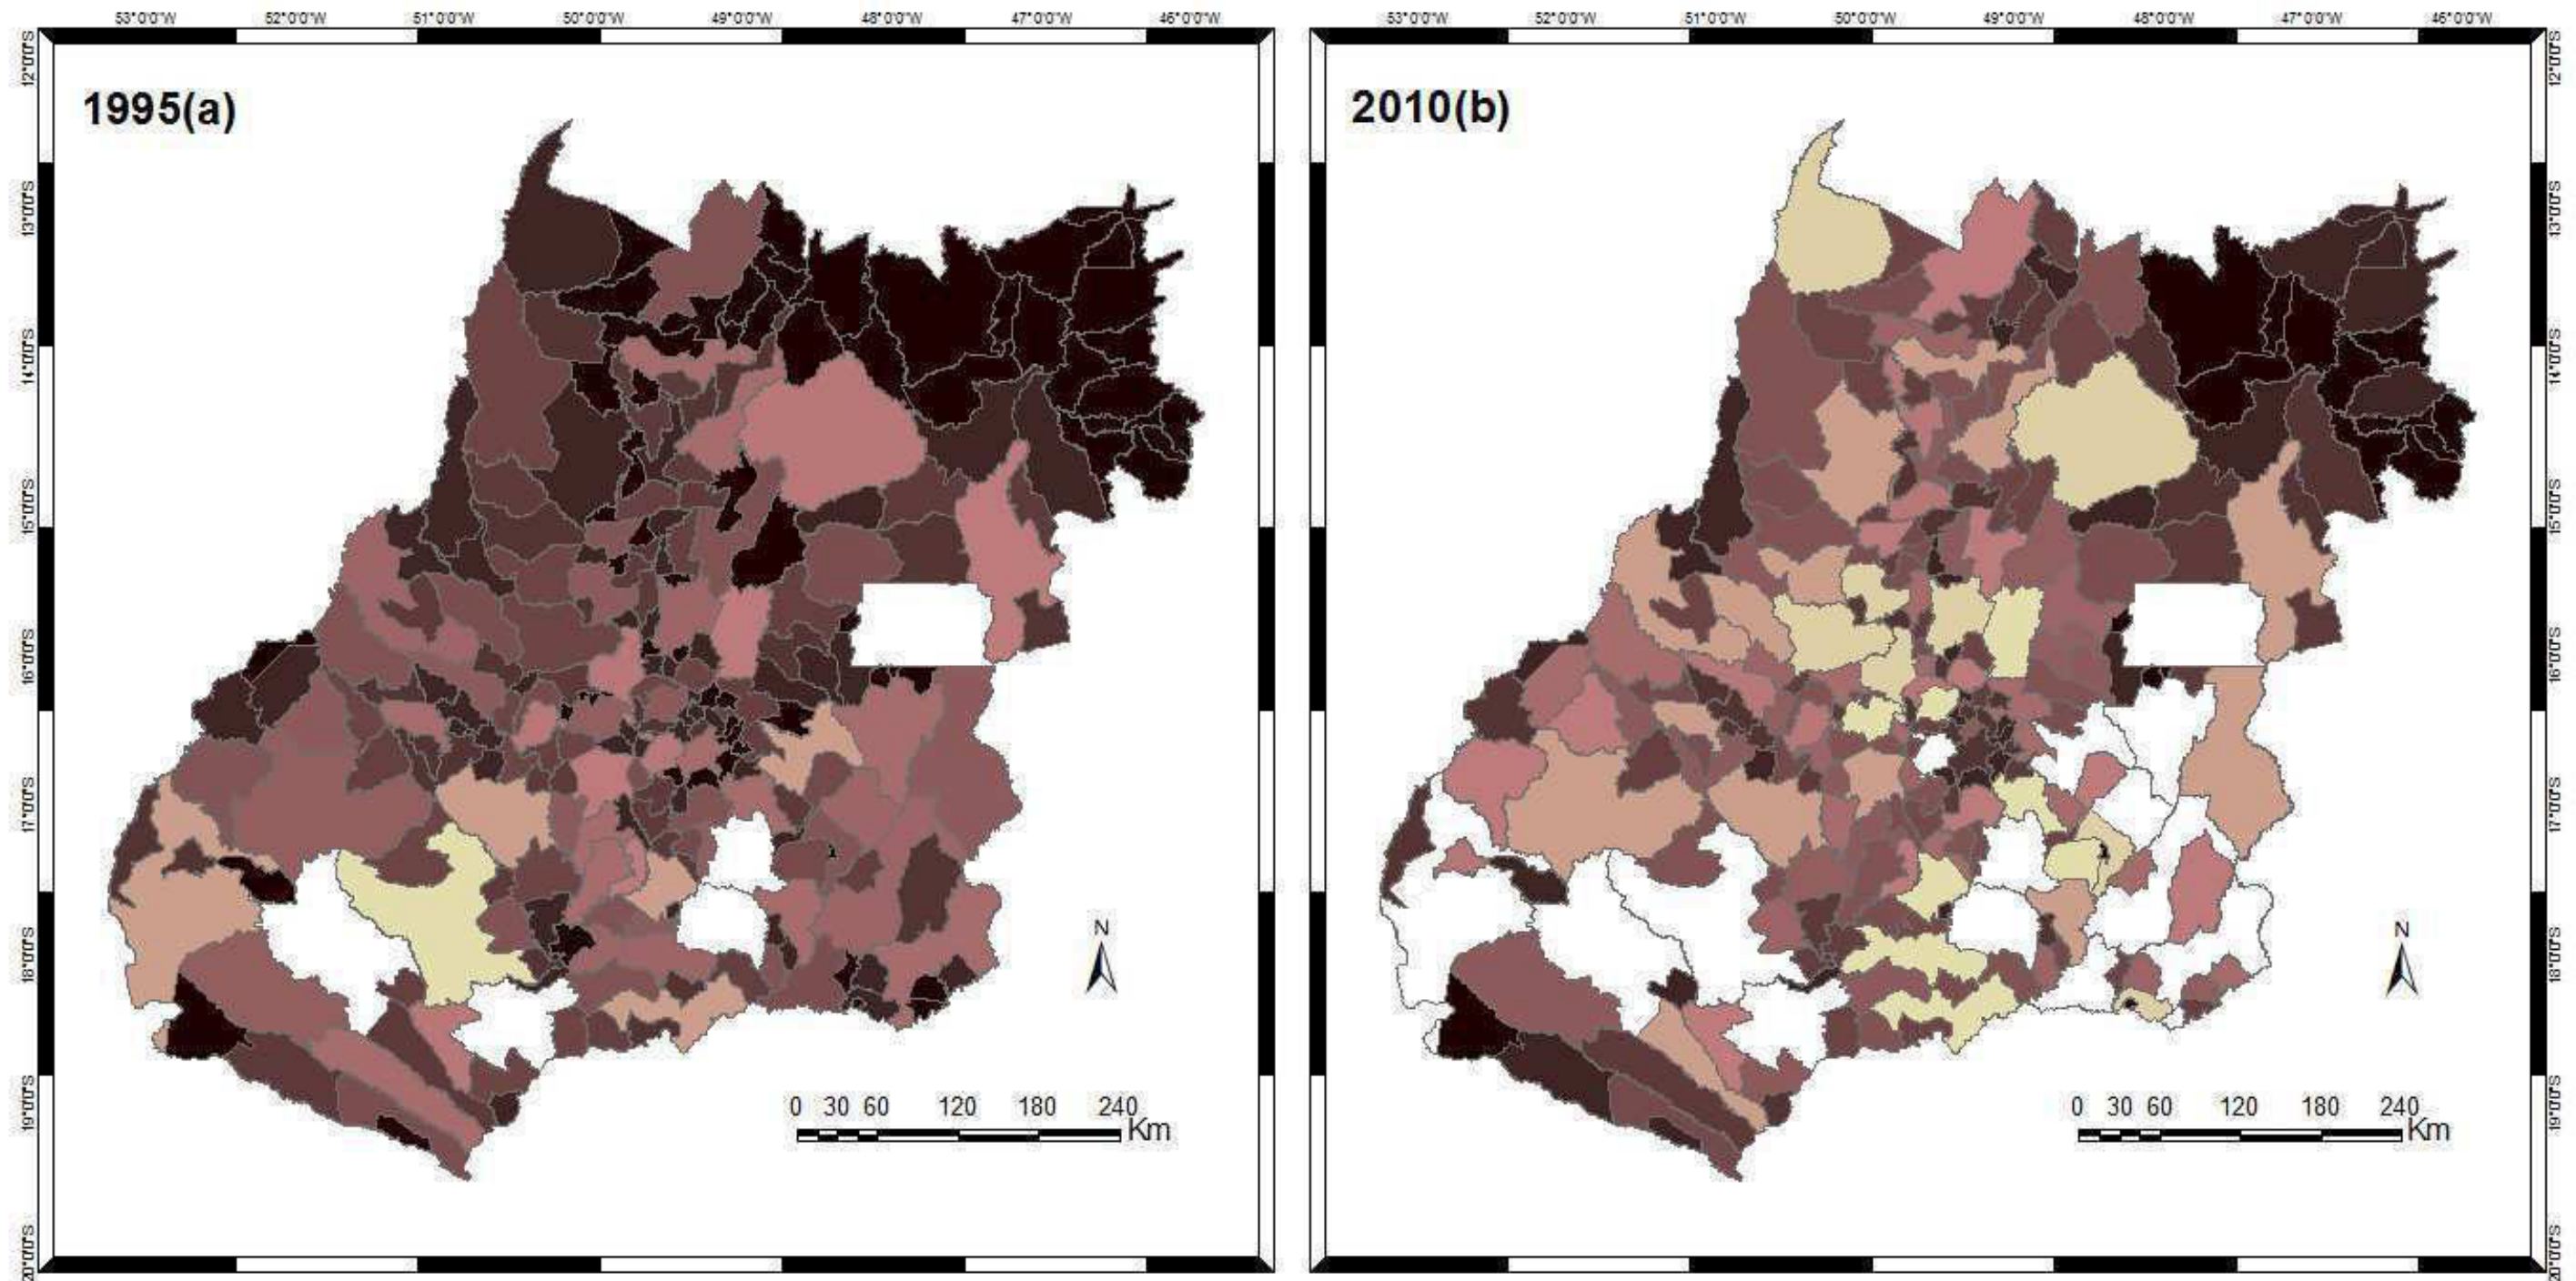
Figura 30: Legenda de cor relacionada ao mapa de classificação temporal (Figura 31).



Fonte: Autor (2013).

A classificação realizada para a produção leiteira, indicada na Figura 31, mostra que os municípios representados com a mesma cor foram agrupados por um mesmo centroide. A Figura 30, que indica os grupos nos quais os municípios foram classificados, é interpretada levando-se em consideração a linha e a coluna onde o neurônio está localizado. Por exemplo: o grupo 6 foi classificado por um neurônio que está disposto na linha 1 e coluna 1; o grupo 24 foi classificado por um neurônio localizado na linha 4 e coluna 4 e, assim, sucessivamente. É importante ressaltar que as cores representadas na Figura 31 são correspondentes ao grupo no qual o município está classificado (Figura 30).

CLASSIFICAÇÃO DA PRODUÇÃO LEITEIRA NO ESTADO DE GOIÁS



INFORMAÇÕES CARTOGRÁFICAS


Projeção Universal Transversa de Mercator - UTM
Datum horizontal: SAD - 69
Datum vertical: Imbituba-SC
Origem da quilometragem: Equador e Meridiano 51°W.Gr.
Fonte: Base Cartográfica Digital (SIEG)
Dados de Área Plantada de Cana - IBGE (2012)

Figura 31: Classificação da produção leiteira no Estado de Goiás, com a utilização de rede neural artificial de Kohonen com dimensão 5X5.
(a) Ano de 1995.(b) Ano de 2010.

Autores: CAMPOS, Eudé S.
PEREIRA, Natasha S.

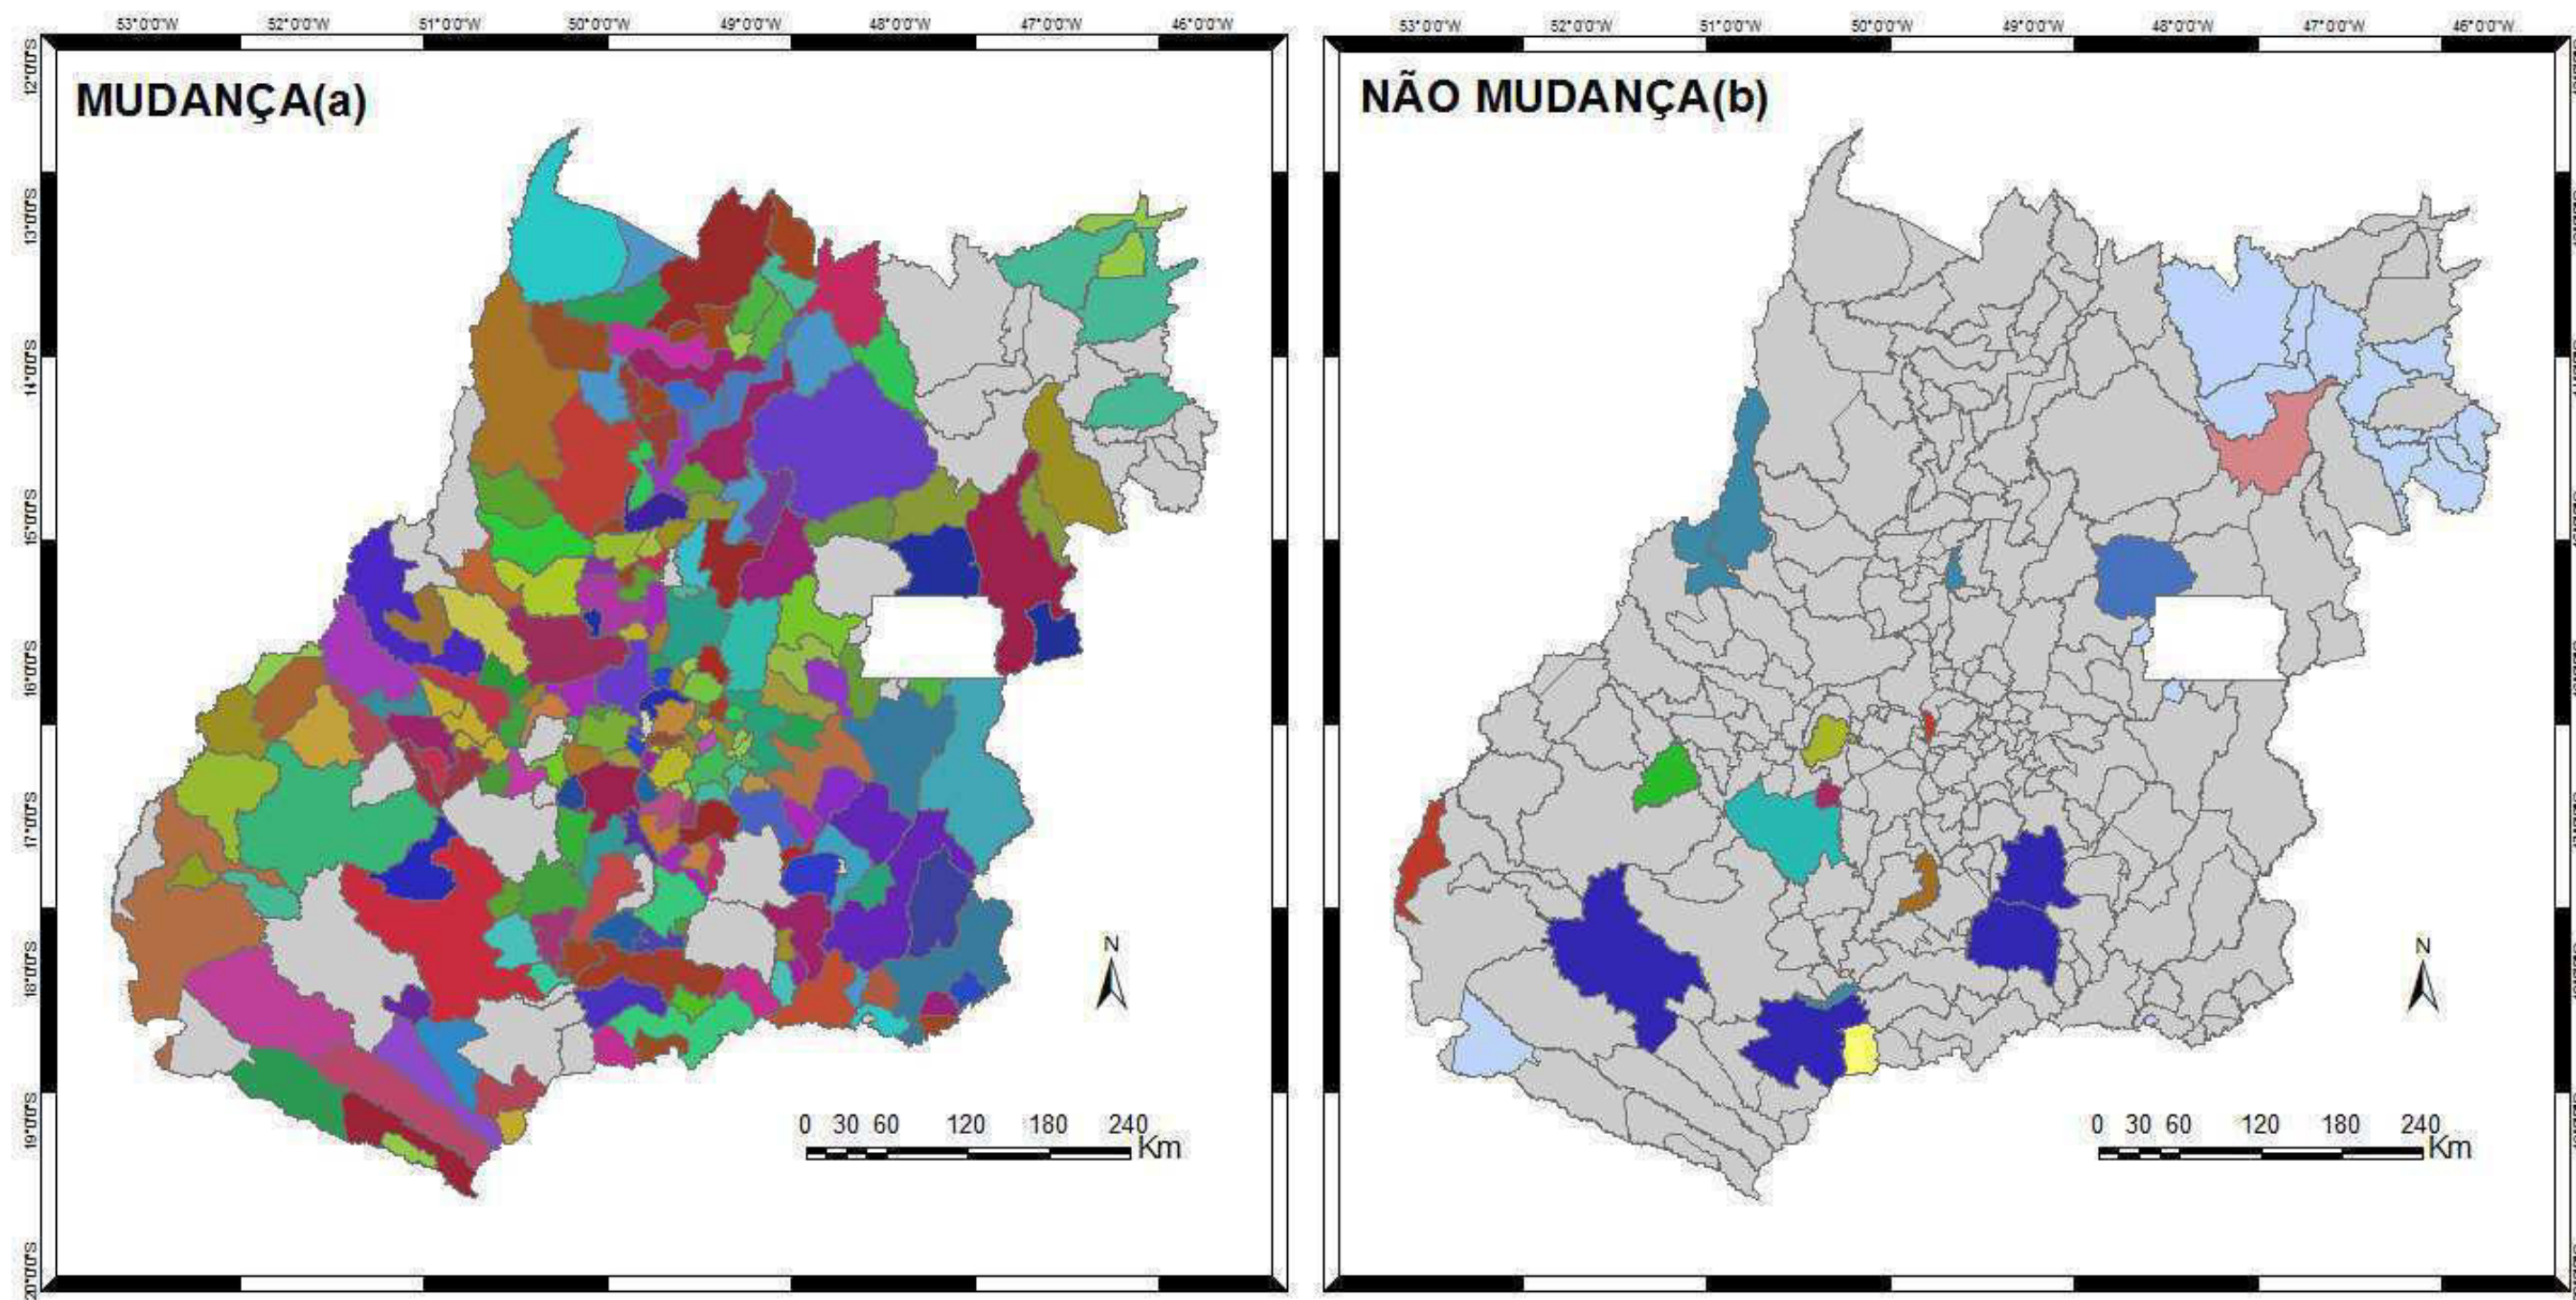
A detecção de mudanças foi realizada levando-se em consideração os dois tempos simultâneos (1995 e 2010), representados pela Figura 33. Todas as cores, exceto a cinza, representadas no mapa (a) da Figura 33 indicam as mudanças descritas conforme a Figura 32 (mudança). As cores, exceto a cinza, no mapa (b) da Figura 33 indicam as não mudanças de grupos conforme a Figura 32 (não mudança). A cor cinza indica, no mapa de mudança (a), os municípios em que não ocorreu mudança (NC) do perfil produtivo. No mapa de não mudança (b) a cor cinza representa os municípios em que ocorreram mudanças (C) do perfil produtivo.

Figura 32: Legenda correspondente aos mapas de mudança e não mudança (Figura 33).



Fonte: Autor (2013).

DETECÇÃO DE MUDANÇAS DA PRODUÇÃO LEITEIRA NO ESTADO DE GOIÁS



INFORMAÇÕES CARTOGRÁFICAS

Projeção Universal Transversa de Mercator - UTM

Datum horizontal: SAD - 69

Datum vertical: Imbituba-SC

Origem da quilometragem: Equador e Meridiano 51°W.Gr.

Fonte: Base Cartográfica Digital (SIEG)

Dados de Área Plantada de Cana - IBGE (2012)

Figura 33: Detecção de mudanças da produção leiteira no Estado de Goiás, com a utilização de rede neural artificial de Kohonen com dimensão 5X5. (a) Mapa de Mudança. (b) Mapa de Não Mudança.

Quadro 16: Análise de mudança da produção para os municípios goianos.

Grupos	Centróide (em litros)	Nº de Municípios	Cenário de Produção Apresentado
2 → 2	17072 → 17072	1	inalterado
4 → 4	46748 → 46748	4	inalterado
8 → 8	22061 → 22061	1	inalterado
10 → 10	4606 → 4606	1	inalterado
11 → 11	5469 → 5469	1	inalterado
12 → 12	7859 → 7859	1	inalterado
14 → 14	16034 → 16034	1	inalterado
15 → 15	2375 → 2375	1	inalterado
16 → 16	4046 → 4046	2	inalterado
20 → 20	806 → 806	18	inalterado
21 → 21	2573 → 2573	4	inalterado
22 → 22	6041 → 6041	1	inalterado
0 → 2	9586 → 17072	1	crescente
0 → 3	9586 → 29871	1	crescente
0 → 13	9586 → 13620	1	crescente
0 → 17	9586 → 6935	1	decrésciente
2 → 8	17072 → 22061	2	crescente
2 → 9	17072 → 32735	1	crescente
5 → 1	7392 → 11791	1	crescente
5 → 4	7392 → 46748	1	crescente
6 → 2	8507 → 17072	2	crescente
6 → 3	8507 → 29871	1	crescente
7 → 8	11824 → 22061	1	crescente
8 → 4	22061 → 46748	2	crescente
8 → 9	22061 → 32735	2	crescente
9 → 4	32735 → 46748	1	crescente
10 → 0	4606 → 9586	1	crescente
10 → 6	4606 → 8507	1	crescente
10 → 8	4606 → 22061	1	crescente
10 → 12	4606 → 7859	4	crescente
10 → 13	4606 → 13620	4	crescente
10 → 14	4606 → 16034	1	crescente
10 → 16	4606 → 4046	3	decrésciente
10 → 17	4606 → 6935	1	crescente
10 → 21	4606 → 2573	1	decrésciente
10 → 22	4606 → 6041	1	crescente
10 → 23	4606 → 8598	1	crescente
11 → 0	5469 → 9586	1	crescente
11 → 13	5469 → 13620	3	crescente
11 → 14	5469 → 16034	1	crescente
11 → 15	5469 → 2375	1	decrésciente
11 → 19	5469 → 11657	2	crescente
11 → 23	5469 → 8598	2	crescente
12 → 8	7859 → 22061	1	crescente
12 → 17	7859 → 6935	1	decrésciente

12 → 22	7859 → 6041	1	decescente
13 → 4	13620 → 46748	2	cescente
13 → 6	13620 → 8507	1	decescente
13 → 8	13620 → 22061	4	cescente
13 → 9	13620 → 32735	1	cescente
13 → 10	13620 → 4606	1	decescente
13 → 16	13620 → 4046	1	decescente
13 → 24	13620 → 9689	1	decescente
14 → 2	16034 → 17072	1	cescente
14 → 3	16034 → 29871	2	cescente
14 → 4	16034 → 46748	1	cescente
15 → 0	2375 → 9586	1	cescente
15 → 5	2375 → 7392	1	cescente
15 → 10	2375 → 4606	1	cescente
15 → 11	2375 → 5469	2	cescente
15 → 13	2375 → 13620	3	cescente
15 → 16	2375 → 4046	7	cescente
15 → 17	2375 → 6935	2	cescente
15 → 19	2375 → 11657	1	cescente
15 → 21	2375 → 2573	4	cescente
15 → 22	2375 → 6041	2	cescente
16 → 0	4046 → 9586	1	cescente
16 → 2	4046 → 17072	1	cescente
16 → 5	4046 → 7392	1	cescente
16 → 6	4046 → 8507	2	cescente
16 → 10	4046 → 4606	3	cescente
16 → 11	4046 → 5469	1	cescente
16 → 12	4046 → 7859	2	cescente
16 → 14	4046 → 16034	1	cescente
16 → 17	4046 → 6935	1	cescente
16 → 18	4046 → 10481	1	cescente
16 → 19	4046 → 11657	1	cescente
16 → 22	4046 → 6041	3	cescente
16 → 23	4046 → 8598	1	cescente
16 → 24	4046 → 9689	1	cescente
17 → 2	6935 → 17072	1	cescente
17 → 9	6935 → 32735	1	cescente
17 → 23	6935 → 8598	2	cescente
18 → 0	10481 → 9586	1	decescente
18 → 5	10481 → 7392	1	decescente
18 → 8	10481 → 22061	1	cescente
18 → 9	10481 → 32735	1	cescente
19 → 3	11657 → 29781	1	cescente
19 → 4	11657 → 46748	2	cescente
19 → 9	11657 → 32735	1	cescente
20 → 5	806 → 7392	1	cescente
20 → 6	806 → 8507	1	cescente
20 → 7	806 → 11824	1	cescente

20 → 10	806 → 4606	4	crecente
20 → 11	806 → 5469	8	crecente
20 → 12	806 → 7859	3	crecente
20 → 15	806 → 2375	9	crecente
20 → 16	806 → 4046	4	crecente
20 → 17	806 → 6935	1	crecente
20 → 18	806 → 10481	2	crecente
20 → 21	806 → 2573	8	crecente
20 → 22	806 → 6041	5	crecente
21 → 3	2573 → 29871	2	crecente
21 → 8	2573 → 22061	1	crecente
21 → 10	2573 → 4606	2	crecente
21 → 12	2573 → 7859	1	crecente
21 → 13	2573 → 13620	1	crecente
21 → 15	2573 → 2375	2	decrecente
21 → 16	2573 → 4046	6	crecente
21 → 23	2573 → 8598	2	crecente
21 → 24	2573 → 9689	2	crecente
22 → 2	6041 → 17072	1	crecente
22 → 3	6041 → 29871	1	crecente
22 → 6	6041 → 8507	1	crecente
22 → 8	6041 → 22061	1	crecente
22 → 14	6041 → 16034	1	crecente
22 → 17	6041 → 6935	1	crecente
22 → 18	6041 → 10481	2	crecente
22 → 23	6041 → 8598	2	crecente
22 → 24	6041 → 9689	2	crecente
23 → 0	8598 → 9586	1	crecente
23 → 2	8598 → 17072	3	crecente
23 → 7	8598 → 11824	2	crecente
23 → 12	8598 → 7859	1	decrecente
23 → 13	8598 → 13620	1	crecente
24 → 8	9689 → 22061	1	crecente
24 → 9	9689 → 32735	1	crecente
24 → 14	9689 → 16034	1	crecente

Fonte: Autor (2013). NC = 36 municípios; C = 210 municípios.

Ao analisar o perfil da produção leiteira é possível perceber que, dos 246 municípios goianos, 210 (85%) sofreram mudanças de cenário e 36 (15%) permaneceram inalterados (destes, 1 do grupo NC:2 (cerca de 17.072 litros), 4 do grupo NC:4 (cerca de 46.748 litros) , 1 do grupo NC:8 (cerca de 22.061 litros), 1 do grupo NC:10 (cerca de 4.606 litros), 1 do grupo NC:11 (cerca de 5.469 litros), 1 do grupo NC:12 (cerca de 7.859 litros), 1 do grupo NC:14 (16.034 litros), 1 do grupo NC:15 (cerca de 2.375 litros), 2 do grupo NC:16 (4.046 litros), 18 do grupo NC:20 (cerca de 806 litros), 4 do grupo NC:21(cerca de 2.573 litros) e 1 do grupo NC:22 (cerca de 6.041 litros). As

mudanças (C) detectadas ocorreram em todas as regiões do Estado, sem exceções. Enquanto que as não mudanças (NC) concentram-se no nordeste goiano e alguns municípios distribuídos principalmente nas regiões sul, sudoeste, sudeste, noroeste e parte do Entorno do Distrito Federal (ver Figura 7). Portanto, constata-se que, dos 210 municípios com mudanças, 194 (92%) apresentaram crescimento na produção leiteira. Enquanto 17 (8%) municípios reduziram a produção de leite.

Após a análise da mudança de produção (Quadro 16), foi possível perceber que 33 municípios que eram considerados pequenos produtores aumentaram a produção leiteira acima de 20.000 litros/ano e tornaram-se grandes produtores. Outra análise possível de ser feita refere-se a 5 municípios (Itumbiara, Mineiros, Rio Verde, Silvânia e Pontalina) que eram considerados grandes produtores e aumentaram ainda mais a produção do leite. Há ainda, 17 pequenos produtores que diminuíram a produção. Em uma última análise é possível constatar que 156 municípios goianos eram considerados pequenos produtores e, mesmo ampliando a produção leiteira permaneceram produzindo menos de 20.000 litros de leite/ano, o que os manteve com perfil de pequenos produtores.

O Estado de Goiás, em 2010, mantinha-se entre os maiores produtores de leite do Brasil, com produção de 3,194 bilhões de litros, o que representava 10,4% de participação (4º lugar no ranking nacional)(IBGE, 2010). A pecuária e o agronegócio contribuem com, aproximadamente, 12,84% da composição do Produto Interno Bruto (PIB) do Estado. Nesse caminho, a cadeia produtiva do leite, em 2012, movimentou cerca de R\$ 3 bilhões, o que confirma ser a produção leiteira significativa para o crescimento da economia goiana (SEGPLAN, 2012). Portanto, é justificável que mesmo diante do comportamento de crescimento e expansão do cultivo da cana-de-açúcar nos municípios goianos, os números para o leite também impressionem, demonstrando que a atividade continua sendo atrativa e rentável aos pecuaristas, em todos os 246 municípios goianos.

O cenário demonstrado para a produção leiteira nos municípios goianos demonstra que mesmo diante da entrada da cultura de cana-de-açúcar principalmente nas regiões sul e sudeste do Estado, a cadeia produtiva do leite mostra-se forte e com crescimento para o setor produtivo. As possíveis mudanças relacionadas ao setor agropecuário em Goiás nos leva a perceber que a pecuária de corte e leiteira, por ser uma atividade tradicional e antiga, não se mostra ameaçada em função do cultivo da cana-de-açúcar. Pode-se exemplificar com o município de Quirinópolis, atualmente, o que possui a maior área de plantio para a cana-de-açúcar. Ao analisar o perfil produtivo do rebanho bovino de corte e a produção leiteira, o mesmo continua sendo grande produtor, o que indica que a

expansão da área plantada de cana-de-açúcar provocou modificações no espaço do rebanho sem, contudo, ameaçar a criação bovina e a produção do leite.

6 CONCLUSÕES

O objetivo primordial da pesquisa que era mensurar a eficácia da aplicação de detecção de mudanças temporais, como proposta metodológica, para caracterizar o setor produtivo da cana-de-açúcar, pecuária bovina de corte e leiteira dos municípios goianos, foi alcançado. Nesse sentido, este trabalho propôs o uso de um processo de sinclassificação com a utilização de uma rede neural artificial não supervisionada do tipo SOFM.

As redes SOFM são conhecidas como sistemas de aprendizado competitivo não supervisionado que conseguem extrair características a partir de um conjunto de dados de treinamento. A partir de uma camada bidimensional de neurônios, representada por um conjunto de pesos iniciais, o algoritmo de treinamento do SOFM realiza uma auto-organização destes neurônios de forma que os mesmos passem a representar características do conjunto de treinamento utilizadas (KOHONEN, 1982). A escolha desta metodologia foi direcionada com o intuito de comprovar se a rede conseguiria caracterizar os dados e classificá-los de forma coerente. Tal hipótese foi confirmada, conforme pode ser verificado nas análises apresentadas e discutidas nas Seções 5.2, 5.3 e 5.4 do trabalho.

Na Seção 5.2 foi realizado o processo de sinclassificação, com os dados de produção, para a cana-de-açúcar, pecuária bovina de corte e de leite. O processo compreendeu três passos básicos: o treinamento da rede, a ordenação e convergência da mesma. Como parâmetro de análise estabeleceu-se o Índice de Similaridade Intra Grupo (I_{SIG}), no qual a similaridade entre componentes de um mesmo grupo foi mensurada e os valores encontrados, em um intervalo de 0 a 1, deveriam ser os menores possíveis, ou seja, quanto mais próximos de 0, menor o I_{SIG} , demonstrando elevado grau de semelhança entre os componentes de um mesmo grupo. Na prática, a rede neural demonstrou ser capaz de identificar tal similaridade e fazer a classificação de forma correta. Outra conclusão feita foi a de que a RNA utilizada é sensível aos dados de entrada e estável. Ou seja, independente de sua dimensão, seus pesos finais apresentam distribuições de valores coerentes. Na Seção 5.3 discutiu-se a aplicabilidade e as vantagens da utilização do método testado.

O mesmo pode ser aplicado em diferentes situações e contextos de pesquisa quantitativa e qualitativa. Finalmente, na Seção 5.4 realizou-se o processo de detecção de mudanças para os três conjuntos de dados produtivos de Goiás. Os cenários apresentados nos mapas gerados demonstram que o método de sinclassificação é válido para a realidade goiana e reflete o real comportamento dos municípios do Estado, quanto aos seus perfis de produção.

Em síntese, a classificação temporal realizada mostrou que independente das dimensões da rede, o algoritmo de aprendizagem demonstra ser capaz de capturar os dados e agrupá-los de forma coerente e precisa em relação aos índices oficiais, disponibilizados pelo Governo de Goiás e pelo IBGE, relativos aos três perfis de produção pesquisados, para os 246 municípios goianos. Logo, o intuito de agrupar por nível de similaridade Intra Grupo foi alcançado.

Conforme já apresentado na Seção 4.3.1, o protótipo desenvolvido possui interfaces de fácil manuseio de dados relacionais, vetoriais e de tratamento de mapas auto-organizáveis (rede SOFM). Por meio do protótipo desenvolvido, foi possível comprovar a funcionalidade do algoritmo de aprendizagem, para realizar as classificações propostas. As pesquisas de Kohonen (1997, 1982) e Haykin (2001) foram vitais para direcionar a seleção dos parâmetros livres do algoritmo de treinamento dos classificadores utilizados na fase de sinclassificação. Uma vez que não há uma forma determinística para a seleção dos parâmetros livres dos SOFMs, as diretrizes de seleção adotadas foram importantes na obtenção de auto-organização das redes utilizadas.

Os testes laboratoriais permitiram comprovar que o comportamento da classificação foi preciso e demonstra a real situação dos municípios pesquisados, em relação aos indicadores de: área plantada de cana-de-açúcar, número de cabeças do rebanho de corte e a quantidade em litros de leite utilizados. Tais dados foram disponibilizados pela plataforma do Instituto Brasileiro de Geografia e Estatística (IBGE) e as análises mostraram que a maioria dos municípios goianos são considerados pequenos produtores e há alguns municípios que se destacam pela elevada produção, tanto para a cana-de-açúcar, pecuária bovina de corte e leite (ver Seção 4.1.3).

Em qualquer âmbito, quer seja público ou privado, um processo de classificação temporal pode ser aplicado em áreas diversificadas como, por exemplo, na segurança pública, na saúde, na educação, na economia, dentre outros. A partir daí, torna-se possível a implementação de políticas públicas ou privadas que possibilitem melhorias na qualidade de vida das pessoas, em diversas circunstâncias. Como exemplos de aplicabilidade ao processo de classificação destaca-se: a utilização do software DMB – SOFM em análise de dados que contemplem todos os municípios brasileiros, para avaliar o grau de expansão da cultura canavieira ou qualquer outro indicador de produção; aplicar o modelo de rede neural produzido em pesquisas voltadas ao campo educacional, abordando classificação temporal, para mensurar o nível de aprendizagem escolar entre os discentes de uma determinada série; usar o modelo produzido em classificação temporal, para dados de outros setores produtivos em Goiás, não apenas para o tempo pesquisado, mas gerar informações a partir de outras temporalidades, de acordo com o nível de interesse; utilizar o modelo de rede DMB –

SOFM, dentro das Ciências Biológicas, para classificar e quantificar espécies, doenças e fenômenos biológicos em geral; usar a rede para propor uma classificação relacionada aos indicadores de qualidade da água de um rio, represa ou nascentes, dentre outros. Logo, é necessário afirmar que o protótipo utilizado na pesquisa apresenta-se como um recurso tecnológico de fácil manuseio, utilização e possa estar disponível a qualquer público que tenha interesse em desenvolver pesquisas quantitativas e qualitativas, em diversas áreas do conhecimento.

Outra conclusão que pode ser feita, quanto ao processo de detecção de mudanças realizado e disposto na Seção 5.4 da pesquisa, refere-se a sua validação, importância e aplicabilidade. Para os indicadores de produção pesquisados, após análise comparativa da classificação feita em relação aos dados oficiais do IBGE e da SEGPLAN, é possível dizer que os mapas resultantes do processo de detecção de mudança condizem com a realidade dos municípios goianos. Nesse sentido, foi possível validar o processo realizado. Quanto à importância e aplicabilidade, conforme já discutida no parágrafo anterior, novamente reitera-se para as inúmeras possibilidades de utilização do método em diversas áreas do conhecimento, como na matemática, biologia, geografia, geologia, física, química, dentre outras.

Portanto, conhecer as dimensões da terra para mensurar ou classificar o tamanho de áreas degradadas provocadas pela antropização, quantificar e mapear regiões ocupadas por safra agrícola ou pecuária, identificar e classificar espécies nativas de uma determinada área geográfica, dentre inúmeras possibilidades, é fato que as ferramentas tecnológicas utilizadas na pesquisa são eficazes para auxiliar na proteção ambiental do planeta, ser útil em planos de desenvolvimento urbanos e/ou rurais e, sobretudo, viáveis para ajudar no desenvolvimento humano, em diferentes espaços.

Vê-se que essa pesquisa pode ser utilizada não somente para os dados apresentados, mas também em outros setores produtivos do Estado de Goiás, demais Estados e para o País. Ainda nesta perspectiva, o método proposto pode ser integrado com Sistemas de Informações Geográficas (SIG) para implementar um sistema capaz de reduzir a dimensão dos dados apresentados, fornecer respostas rápidas e precisas para os problemas levantados, minimizar custos de pesquisa e tornar a tecnologia aliada ao homem em avanços científicos, sociais, ambientais e tecnológicos.

6.1 Trabalhos Futuros

O desenvolvimento deste trabalho e a vasta informação obtida em todo o processo de construção da pesquisa, a coleta de dados, a utilização dos softwares e a análise dos resultados tornaram-se fonte de incentivo, reflexão e estímulo para o desenvolvimento de novos projetos. Portanto, a partir deste trabalho, pode-se estabelecer como trabalhos futuros:

a – Ajustar ou complementar o algoritmo SOFM de modo que seja aplicado em pesquisas que contemplem um aspecto multitemporal. Ou seja, aplicar a rede neural artificial em análises que adotem uma série temporal contínua que permita avaliar a classificação e a detecção de mudanças em um aspecto multitemporal possibilitando um estudo mais detalhado do cenário que se pretende pesquisar..

b – Aplicar o método em análises simultâneas de múltiplos indicadores de produção de forma concomitante (análise multivariada). A pesquisa pode fornecer informações úteis aos setores produtivos privados e públicos para direcionar investimentos em regiões que possuam perfil ideal para uma determinado conjunto de produções em detrimento de outras.

6.2 Publicações do autor relacionadas ao trabalho

6.2.1 Capítulos de livros publicados

SILVA, S. D.; SILVA, N. C. ; **CAMPOS, E. S.** Geotecnologia e história ambiental: o uso de detecção de mudança temporal na produção sucroalcooleira em Goiás, Brasil.. In: In: Quinta Ferreira, M., Barata, M. T., Lopes, F. C., Andrade, A. I., Henriques, M. H., Pena dos Reis, R., Ivo Alves, E. (Org.). Para Desenvolver a Terra: MEMÓRIAS E NOTÍCIAS DE GEOCIÊNCIAS NO ESPAÇO LUSÓFONO. 1ed. Coimbra: Imprensa da Universidade de Coimbra, 2012, v. 3, p. 1-10.

SILVA, N. C.; CARVALHO JUNIOR, O. A.; **CAMPOS, E. S.**; PEREIRA, N. S. Métodos de Detecção de Mudanças para Análises Temporais do Uso do Solo. In: Genilda D’Arc Bernardes; Ricardo Antonio Gonçalves Teixeira; Roberto Prado de Moraes. (Org.). Entre Lugares: Espaços Interdisciplinares em Sociedade, Tecnologia e Meio Ambiente. 1 ed. Goiânia: América, 2012, v. v. 1, p. 279-302.

6.2.2 Resumos expandidos publicados em anais de congressos

Silva, N. C. ; SILVA, S. D. ; CAMPOS, E. S. Geotecnologia e História Ambiental: Detecção de Mudança em Série Temporal na Produção Sucroalcooleira em Goiás (Brasil). In: I Congresso Internacional GeoCiências na CPLP, 2012, Coimbra. I Congresso Internacional GeoCiências na CPLP: 240anos de Geociências na CPLP. Coimbra: Centro de Geociências e Centro de Geofísica da Universidade de Coimbra,, 2012, Coimbra. I CONGRESSO INTERNACIONAL GEOCIÊNCIAS NA CPLP. Coimbra: Centro de Geociências & Centro de Geofísica da Universidade de Coimbra, 2012. v. 1, p. 297-297.

REFERÊNCIAS

- ADENIYI, P. O. Digital analysis of multitemporal Landsat data for land-use/land-cover classification in semi-arid area of Nigeria. *Photogrammetric Engineering and Remote Sensing*, v. 51, p. 1761-1774. 1985.
- ALECRIM, E. **Redes Neurais Artificiais**. 2004. Disponível em: <http://www.infowester.com/redesneurais.php>. Acesso em: 27 de out de 2012.
- ALVAREZ, A. B.; LUQUE, B. **Rede Neural de Kohonen e Outras Técnicas para Treinamento Não-Supervisionado**. São Paulo: Unicamp. Faculdade de Engenharia Elétrica. v. 1. 2003. 39 p.
- ANDERBERG, M. R. 1973. **Cluster Analysis for Applications**. Academic Press, New York.
- ANDRADE, E. T.; CARVALHO, S. R. G.; SOUZA, L. F. Programa do ProÁlcool e o Etanol no Brasil. *ENGEVISTA*, v. 11, n. 2. p. 127-136. 2009.
- ANUÁRIO DA CANA. **Brazilian Sugar and Ethanol Guide**. São Paulo: Prol Cana. v. 1. 418 p. 2009.
- ASSIS, C. de *et al.* **Nossas Plantas: cerrado**. São Paulo: FTD S.A., 1994.
- BACCARIN, J. G. *et al.* **Os efeitos da produção de biocombustíveis na estrutura agrária no Centro-Sul do Brasil**. Relatório de Pesquisa do Projeto de Cooperação Técnica “Apoio às Políticas e à Participação Social no Desenvolvimento Rural Sustentável” – PCT IICA/NEAD. Fundação de Apoio à Pesquisa, Ensino e Extensão (Funep). Jaboticabal. São Paulo. 2010.
- BARRETO, G. A. **Redes Neurais Não-Supervisionadas para Processamento de Sequências Temporais**. 1998. 152f. Dissertação (Mestrado em Engenharia Elétrica), USP, São Carlos-SP, 1998.
- BARROS, R. **Energia para um novo mundo**. Rio de Janeiro: CREA. 2. ed. v. 1. 160 p. 2007.
- BASHEER, I. A.; HAJMEER, M. Artificial neural networks: fundamentals, computing, design, and application. *Journal of Microbiological Methods*, v. 43, p. 3-31, 2000.
- BECKER, S. “Unsupervised learning procedures for neural networks”, *Internacional Journal of Neural Systems*, v. 2, p. 17-33, 1991.
- BEVINGTON, P. R.; ROBINSON, D. K. **Data reduction and error analysis for the physical sciences**, 2 ed., WCB/McGraw-Hill, (1992). 336p.
- BINS, L. S., ERTHAL, G. J., FONSECA, L. M. G. Um método de classificação não-supervisionada por regiões. *In: SIMPÓSIO BRASILEIRO DE COMPUTAÇÃO GRÁFICA E PROCESSAMENTO DE IMAGENS*. n.6. Recife. 1995. **Anais do SIBGRAPI**. Recife: SBC/UFPE. v.2, p.65-68. 1995.
- BOTTER, E. A.; NASCIMENTO JUNIOR, C. L; YONEYAMA, T. Redes neurais auto-organizáveis para classificação de sinais eletrocardiográficos atriais. **Revista integração**. São Paulo:Universidade São Judas Tadeu. Ano XI, n. 40. p.51-56, 2005.

BRAGA, A. P, CARVALHO, A. C. P. L. F., LUDERMIR, T. B. **Redes Neurais Artificiais – Teoria e Aplicações**. 1. ed, LTC Editora , Brasil. 2000.

BRASIL, MMA-MINISTÉRIO DO MEIO AMBIENTE. **Plano de ações para preservação e controle de desmatamento e das queimadas no cerrado - PPCERRADO**. Brasília. 2009. Disponível em: <<http://www.ministeriodomeioambiente.gov.br>>. Acesso em: 13 out. 2012.

BRASIL. Decreto Nº 6961, de 17 de setembro de 2009. **Aprova a Lei de Zoneamento Agroecológico da Cana-de-Açúcar**. Disponível em: < **Erro! A referência de hiperlink não é válida.**>. Acesso em 30 nov. 2012.

BRASIL. Decreto Nº 76.593, de 14 de novembro de 1975. **Institui o Programa Nacional do Alcool - ProAlcool**. Disponível em: <http://www6.senado.gov.br/legislacao/ListaPublicacoes.Action?id=123069>. Acesso em: 30 nov. 2012.

BRASIL. Ministério da Agricultura, Pecuária e Abastecimento. **Anuário estatístico da agroenergia**. Brasília: Mapa/ACS, 2006. 160 p. Disponível em: http://www.agricultura.gov.br/images/MAPA/arquivos_portal/anuariocana.pdf. Acesso em: 10 out. 2012.

BRASIL. Ministério da Indústria e Comércio. **Estado da arte da produção de etanol a partir da madeira**. Brasília: MIC/STI, 1981. 190 p.

CAMARA, G. **Anatomia de sistemas de informações geográficas: visão atual e perspectivas de evolução**. In: ASSAD, E.; SANO, E., ed. Sistema de informações geográficas: aplicações na agricultura. Brasília, DF: Embrapa, 1993.

CÂMARA, G.; DAVIS, C.; MONTEIRO, A. M. V. **Introdução à Ciência da Geoinformação**. 2. ed. v. 2. p.1-5. São José dos Campos: INPE, 2001.

CANASAT - **Mapeamento de cana-de-açúcar via imagens de satélite de observação da terra. Relatório de área de cana, safra e reforma na região Centro-Sul**. 2010. Disponível em: <http://www.dsr.inpe.br/mapdsr/index.jsp>. Acesso em: 25 agost. 2012.

CAMPOS, N. A. de. **Análise de Dados**. Coimbra: Departamento de Física da FCTUC, 1995/1996.

CARVALHO, A.; LUDEMIR, A. **Fundamentos de Redes Neurais Artificiais: 11ª Escola de Computação**. Imprinta Gráfica e Editora LTDA, 1998.

CARVALHO, A. C. P. L. F. et al. **Fundamentos de Redes Neurais Artificiais**. NCE – UFRJ. Rio de Janeiro. 1998.

CENSO AGROPECUÁRIO, 1985 e 2006. Instituto Brasileiro de Geografia e Estatística. Disponível em: <<http://www.ibge.gov.br>>. Acesso em julho de 2012.

CHANCHETTI, F. R. **Redes Neurais**. 2010. 30f. Dissertação (Mestrado da Faculdade de Tecnologia), UNICAMP, Campinas-SP, 2010.

CHORLEY, R. J.; HAGGETT, P. (org.). **Modelos físicos e de informação em geografia**. Rio de Janeiro : EDUSP/Livros Técnicos e Científicos, 1975, 260p.

_____. **Modelos sócio-econômicos em geografia**. Rio de Janeiro : EDUSP/Livros Técnicos e Científicos, 1975, 274p.

_____. **Modelos integrados em geografia**. Rio de Janeiro : EDUSP/Livros Técnicos e Científicos, 1974, 221p.

CONAB - COMPANHIA NACIONAL DE ABASTECIMENTO. **Acompanhamento da safra brasileira: cana de açúcar, terceiro levantamento**. Brasília-DF. n. 3. v. 3. 20 p. 2011. Disponível em: < http://www.conab.gov.br/OlalaCMS/uploads/arquivos/11_12_08_11_00_54_08.pdf > Acesso em 5 nov. 2012.

CONAB - COMPANHIA NACIONAL DE ABASTECIMENTO. **Perfil do setor de açúcar e álcool no Brasil**. Brasília-DF. v.1, 76 p. 2008. Disponível em: <http://www.conab.gov.br> Acesso em: 13 ago/2012.

CORREA, V. H. C. O. **Desenvolvimento e a Expansão recente da produção agropecuária no Centro-Oeste**. 2013. 282f. Tese (Doutorado em desenvolvimento econômico). Universidade Estadual de Campinas. Campinas – SP, 2013.

CRÓSTA, A. P. **Processamento digital de imagens de sensoriamento remoto**. ed. ver. Campinas: IG/UNICAMP, 1993. 170 p.

DAIANESE, R. C. **Sensoriamento remoto e geoprocessamento aplicado ao estudo temporal do uso da terra e na comparação entre classificação não-supervisionada e análise visual**. 2001. 185 f. Dissertação (Mestrado em Ciências Agrônômicas), UNESP, Botucatu-SP, 2001.

DUDA, R. O.; HART, P. E.; STORK, D. G. **Pattern Classification**. John Wiley & Sons, New York, 2000.

EHLERS, R. S. **Análise de series temporais**. São Paulo. 5. ed. v. 1. 118 p. 2009. Disponível em: <http://www2.icmc.usp.br/~ehlers/stemp/stemp.pdf>. Acesso em: 10 out. 2012.

EITEN, G. Vegetação do cerrado. Pp. 9-65. In: M.N. Pinto (org.). **Cerrado - caracterização, ocupação e perspectivas**. Brasília, Editora UnB, 1990.

EVERITT, B. S; DUNN, G. **Cluster analysis**. 3rd ed. London: Heinemann Educational Books, 2001. 122p.

FALCONI, L. C. **A Exploração Econômica do Cerrado: Formas atuais e caminhos futuros**. Goiânia: UCG, 2005.

FAUSETT, L. **Fundamentals of neural networks: architectures, algorithms, and applications**. Upper Saddle River. New Jersey: Prentice Hall. 1994. 459 p.

FERREIRA, Henrique Duarte. *A Conquista do Cerrado*. In PEREIRA, Diamantino Alves. **Agricultura de Goiás – Análise & Dinâmica**. Goiânia: UCG, 2004.

FIGUEIREDO, D. C. **Conceitos Básicos de Sensoriamento Remoto**. n. 1. 2005. 30p. Disponível em http://www.conab.gov.br/conabweb/download/SIGABRASIL/manuais/conceitos_sm.pdf. Acesso em: 15 jul. 2012.

FLOREK, K. J.; Lukaszewicz, J.; Perkal, H. Steinhaus and S. Zubrzycki. 1951. Sur la liason et la division des points d'un ensemble fini. *Colloquium Mathematicae* 2: 282-285.

FLORENZANO, T. G. **Iniciação em sensoriamento remoto**. São Paulo: Oficina de textos – 3.ed. v. 1. 2011. 128 p.

FORESMAN, T. W. (ed.). **The history of Geographic Information Systems: perspectives from the pioneers**. New Jersey : Prentice Hall, 1998, 397p.

FRANCISCO, C. A. C. **REDE DE KOHONEN: Uma ferramenta no estudo das relações tróficas entre espécies de peixes**. 2004. 126f. Dissertação (Mestrado em Ciências). Universidade Federal do Paraná, Curitiba, 2004.

FREEMAN, James A. e SKAPURA, David M. **Neural Networks: Algorithms, Applications, and Programming Techniques**. Addison-Wesley Publishing, Reading, 1992. 401p.

FREITAS, F.; BITTENCOURT, G. 2003. An Ontology-based Architecture for Cooperative Information Agents. A ser publicado nos **Proceedings of the Internacional Joint Conference on Artificial Intelligence – IJCAI'2003**. Acapulco, México.

GOIÁS. Plano de Desenvolvimento Agrário do Governo Mauro Borges, Governo Mauro Borges Teixeira. Goiânia, 1961: Vol. I – **Análise da Estrutura Econômica do Estado**. Vol. II – Diretrizes para 1961 – 1965.

GOIÁS. Superintendência de Estatística, Pesquisa e Informação. **Estatísticas Municipais**. 2010. Disponível em: www.imb.go.gov.br/. Acesso em: 05 agost. 2012.

GOIÁS. Superintendência de Estatística, Pesquisa e Informação. **Estatísticas Municipais**. 2012. Disponível em: www.seplan.go.gov.br/sepin. Acesso em: 05 agost. 2012.

GONZALEZ, R. C.; WOODS, R. E. **Processamento Digital de Imagens** . São Paulo: Edgard Blucher, 3.ed. p. 345-477. 2010.

GRAY, R.M. Vector quantization. *IEEE ASSP Magazine*, p.4-29, April, 1984.

GUERRA, A. J. T.; MARÇAL, M. S. **Geomorfologia ambiental**. Rio de Janeiro: Bertrand Brasil, 1. ed. v. 3. 2006. 187 p.

HAIR, J.; ANDERSON, R.; TATHAM, R.; Black, W. (2006). **Análise multivariada de dados**. São Paulo: Bookman. 2.ed. v.3. 2006. 254p.

HAYKIN, S. **Redes neurais: princípios e prática**. Porto Alegre: Bookman. 2.ed. v. 6. 2001. 900 p.

HAYKIN, S. **Redes Neurais: Princípios e práticas**. Porto Alegre: Bookman, 2.ed. v.6. 1999. 900p.

HEBB, D. O. **The Organization of Behavior: a neuropsychological theory**. New York: Willey, 1949.

IBGE. Instituto Brasileiro de Geografia e Estatística. **Produção agrícola municipal**. 2010. Sistema IBGE de Recuperação Automática – SIDRA. Disponível em <http://www.sidra.ibge.gov.br/> .Acesso

em 30 out. 2012.

JAIN, A.; DUBES, R. **Algorithms for Clustering Data**. New Jersey: Prentice-Hall, 1.ed. v. 8.1988. 320 p.

JENSEN, J. R. **Introductory digital image processing**. 2 ed. Upper Saddle River, N.J.: Prentice Hall, 1996, 316 p.

KARYPSIS, G. et al. **A Software Package for Partitioning Unstructured Graphs, Partitioning Meshes, and Computing Fill-Reducing Orderings of Sparse Matrices, V4.0**. Technical Report, Department of Computer Science, University of Minnesota, 1998.

KIEL, R. **Detecção de mudanças no uso e na cobertura do solo em uma série temporal de imagens da região da campanha do rio grande do sul**. 2008. 203f. Dissertação (Mestrado em Sensoriamento Remoto e Geoprocessamento). Universidade Federal do Rio Grande do Sul, Porto Alegre, 2008.

KOHONEN, T. **Self-Organizing Maps**. New York. Springer. 3 ed. v. 30. 501 p. 2001.

KOHONEN, T.; MÄKISARA, K. The **self-organizing feature maps**. *Physica Scripta*, 39: 168, 1989.

KOHONEN, T. **Analysis of a simple self-organizing process**. *Biological cybernetics*. 44: 135-140. Springer, 1982.

KOHONEN, T. **Self-organizing maps**. Berlim. Springer-Verlag, 2 ed., 1997.

KOHONEN, T. **Self-Organized formation of topologically correct feature maps**. *Biological Cybernetics*, 43: 59-69, 1982.

KOHONEN, T. **Statistical pattern recognition with neural networks: benchmarking studies**. *In: IEEE International Conference on Neural Networks, San Diego, CA. Proceedings...* IEEE p. 61 – 68, 1988.

KOHONEN, T. **The self-organizing map**. *Proceedings of the IEEE*, 78 (9): 1464 – 1480, 1990.

KOVÁCS, Z. L. **Redes Neurais Artificiais : Fundamentos e aplicações**. 1 ed. São Paulo , SP – Livraria da Física Editora, 1996.

KOVÁCS, Z. L. **Redes Neurais Artificiais : Fundamentos e aplicações**. 2 ed. São Paulo , SP – Livraria da Física Editora, 2002. 174p.

LOPES, Paulo Afonso. **Probabilidades & Estatística**. 1. ed. Rio de Janeiro: R&A, 1999, 174 p.

LUZ, G. M. **Planejamento e Intervencionismo Estatal em Goiás**. Goiânia: UCG, 2001.

KUME, Hitoshi. **Métodos Estatísticos para Melhoria da Qualidade**. 11. ed. São Paulo: Gente, 1993. 245 p.

LIMA, D. A. L. L.; GARCIA, J. R. A evolução da produção de cana-de-açúcar e o impacto no uso

do solo no estado de Goiás. **Estudos sociais e agrícolas**. Rio de Janeiro, vol. 19, n. 2, p. 374-403. 2011.

LIPPMANN, R. An introduction to computing with neural nets. *ASSP Magazine, IEEE [see also IEEE Signal Processing Magazine]*, v. 4, n. 2, p. 4-22, 1987.

LORENA, R. B. **Evolução do uso da terra em porção da Amazônia ocidental (Acre), com uso de técnicas de detecção de mudanças**. 2001. 116f. (INPE-9650-TDI/846). Dissertação (Mestrado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2001.

LOPES, Paulo Afonso. **Probabilidades & Estatística**. 1. ed. Rio de Janeiro: R&A, 1999, 174 p.

LOURENÇO, M. M. **Caracterização das Nuts da Europa de acordo com a dinâmica de ocupação/uso do solo entre 1990 e 2000**. 2010. 108f. Dissertação (Mestrado em Estatística e Gestão de Informação). Lisboa: ISEGI, 2010.

LOYOLA, M. **Caracterização do Setor Sucroalcooleiro no Estado de Goiás**. Escola Superior de Agricultura Luiz de Queiroz. Departamento de Economia, administração e Sociologia. Grupo ESALQ-LOG. USP: Piracicaba. p.1-22. 2010.

MAPA. Ministério da Agricultura, Pecuária e Abastecimento. **Balanco nacional de cana -de-açúcar e agroenergia / Ministério da Agricultura, Pecuária e Abastecimento**. Secretaria de Produção e Agroenergia – Brasília-DF: MAPA /SPA. 2007. 139 p.

MAPA. Ministério da Agricultura, pecuária e abastecimento. **Plano Nacional de Agroenergia**. Secretaria de produção e agroenergia. Brasília-DF. 2. ed. 114 p. 2006. Disponível em: www.agricultura.gov.br/arq_editor/file/Ministerio/planos. Acesso em 30 nov. 2012.

MATHER, P. M. **Computer processing of remotely-sensed images: na introduction**. 3 ed. Chichester: John Wiley & Sons, 1993. 352 p.

MEDEIROS, J. S. **Banco de Dados Geográficos e Redes Neurais Artificiais: Tecnologias de Apoio à Gestão do Território**. 1999. 165f. Tese (Doutorado em Geografia Física), USP-SP, 1999.

MENDEL, J. M.; MACLAREN, R. W. “Reinforcement – learning control and pattern recognition systems,” in *Adaptive learning, and pattern recognition systems: theory and application*, v.66, p.287- 318, New York: Academic Press, 1970.

MENKE, A. B. **Análise de grupos para compartimentação geomorfológica do Estado de Goiás utilizando parâmetros morfométricos em bacias hidrográficas**. 2012. 88f. Dissertação (Mestrado em Geografia). Universidade de Brasília. Brasília – DF, 2012.

MCCULLOCH, W. S.; PITTS, W. H. **A logical calculus of the ideas immanent in nervous activity**. *Bulletin of Mathematical Biophysics*, v. 5, p. 115-133, 1943.

MENDONÇA, R. C. et al. Flora vascular do Bioma Cerrado: checklist com 12.356 espécies. In: SANO, S. M.; ALMEIDA, S. P.; RIBEIRO, J. F. **Cerrado: ecologia e flora**. Planaltina: DF, Embrapa Cerrados, 2008. v.2.

METZ, J.; MONARD, M. C. Projeto e implementação do módulo de Clustering Hierárquico do DISCOVER. **Relatório Técnico 278**, ICMC-USP, 2006.

METZ, J.; MONARD, M. C. Um sistema computacional para avaliar e interpretar os clusters gerados em diferentes níveis da hierarquia. In **XXXIII Conferência Latino-americana de Informática (CLEI 2007)**. San José, Costa Rica. in print, 2007.

MONTEIRO, L. H. A. **Sistemas dinâmicos**. 2 ed. São Paulo: Editora Livraria da Física, 2006.

MMA. Ministério do Meio Ambiente. **Plano de Ação para Prevenção e Controle do Desmatamento e das Queimadas no Cerrado – PPCerrado**. Brasília – DF, 2009. 152p. Disponível em: www.mma.gov.br/florestas/...e.../plano-de-ação-para-cerrado---ppcerrad. Acesso em 15 de set. 2013.

NUNES, T. V. L. **Método de previsão de defeitos em estradas vicinais de terra com base no uso de redes neurais artificiais: trecho de Aquiraz – CE**. 2003. 134f. Dissertação (Mestrado em Engenharia de Transportes). Universidade Federal do Ceará. Fortaleza – CE, 2003.

OJA, M., NIKKILA, J., TORONEN, P., *et al*, 2002, “Exploratory clustering of gene expression profiles of mutated yeast strains” in *Computational and Statistical Approaches to Genomics*, Zhang, W. e Shmulevich, I. (eds), pp. 65-78, Kluwer Press.

OLIVEIRA, T. B. S. **Clusterização de dados utilizando técnicas de redes complexas e computação bioinspirada**. 2008. 112f. Dissertação (Mestrado em Ciências da Computação e matemática computacional). USP/ICMC. São Carlos – SP, 2008.

PACKARD, N. H.; CRUTCHFIELD, J. P.; FARMER, J. D.; SHAW, R. S. (1980). Geometry from a time series. **Physical Review Letters**, 45(9):712–716.

PAULA, J. L. **Pecuária Bovina de Corte em Goiás (1940-2009)**. 2011. 101f. Dissertação (Mestrado em Desenvolvimento e Planejamento Territorial), PUC-GO, 2011.

PEREIRA, B. (2010). Combining Unsupervised and Supervised Neural Networks in Cluster Analysis of Gamma-Ray Burst. **Journal of Data Science** , 327-338.

PROÁLCOOL – Programa Brasileiro de Álcool. Evolução do Programa Nacional do Álcool – Proálcool. **Revista Eletrônica Biodiesel br.com**. v. 1. 68 p. n. 5. Disponível em: <<http://www.biodieselbr.com/proalcool/pro-alcool.htm>>. Acesso em: 10 de set.2012.

RICHARDS, J. A.; JIA, X. **Remote Sensing Digital Image Analysis**. 4 ed. Springer-Verlag Berlin Heidelberg New York, 2006. 454p.

ROGAL JÚNIOR, S. R. **Detecção e classificação de arritmias cardíacas utilizando redes neurais artificiais auto-organizáveis**. 2008. 83f. Dissertação (Mestrado em Informática). Pontifícia Universidade Católica do Paraná, Curitiba, 2008.

ROSENBLATT, F. The perceptron: **A probabilistic model for information storage and organization in the brain**. *Psychological Review*, 1958.

RUMELHART, D. E.; ZIPSER, D. (1985). Feature discovery by competitive learning. *Cognitive Science*, n.9, p.75-112.

RUSSEL, S.; NORVIG, P. “*Artificial intelligence – A Modern Approach*”. Prentice-Hall, new Jersey, 1995, p.563-597.

SALVINI, R. L.; CARVALHO, L. A. V de. **Inteligência Artificial e Sistemas Especialistas**. Rio de Janeiro, 2001, 19p. Apostila 5: Análise de Agrupamentos – Algoritmo K-Means Clustering. Programa de Engenharia de Sistemas e Computação da UFRJ.

SANTOS, A. A. **O zoneamento da cana-de-açúcar para Goiás**. FAEG, Goiatuba, out. 2009. Palestra realizada para a Comissão de Bioenergia da FAEG, 2009.

SANTOS, A. M. F. T.; SOUZA, F. E. Trabalho árduo, trabalho árido: a degradação do trabalhador na dinâmica do agronegócio sucroalcooleiro no município de Itaberaí-GO. **Revista Visão Acadêmica**; n. 4. 2012. Universidade Estadual de Goiás; UnU Goiás; www.coracoralina.ueg.br

SENDRA, J. **Sistemas de Información Geográfica**. Ediciones Rialp, S. A , Madrid, 2.ed, p.206-230, 1997.

SEPLAN. **Goiás em dados**. 2009. Disponível em <http://www.seplan.go.gov.br/sepin/>. Acesso em: 01 out. 2012.

SEPLAN. **Goiás em dados**. 2011. Disponível em <http://www.seplan.go.gov.br/sepin/>. Acesso em: 01 out. 2012.

SEPLAN. **Goiás em dados**. 2012. Disponível em <http://www.seplan.go.gov.br/sepin/>. Acesso em: 01 out. 2012.

SEPLAN. **Investimentos nos setores industrial e de serviços alcançarão R\$ 27,8 bilhões até 2015**. Disponível em <http://www.seplan.go.gov.br/sepin/>. Acesso em: 01 out. 2012.

SEPLAN-GO/SEPIN. **Perfil competitivo das regiões de planejamento do Estado de Goiás**. 2005. Disponível em <http://www.sgc.goias.gov.br/upload/.../f40892f24f7def77a05e7bce682943ff>. Acesso em: 01 out. 2012.

SILVA, A. A.; MIZIARA, F. **A expansão da fronteira agrícola em Goiás e a localização das usinas de cana-de-açúcar**. 2010 (mimeo).

SILVA, Adailton Lopes Torres da. **Estado, Planejamento e Gestão Pública em Goiás: os governos Mauro Borges e Marconi Perillo**. Dissertação (Mestrado) – Instituto de Ciências Humanas e Filosofia/UFG, Goiânia, 2003.

SILVA, N. C. **Classificação semi-automática de imagens de sensoriamento remoto por meio de síntese genética de redes neurais artificiais**. 2003. 121f. Tese (Doutorado em Processamento de Dados e Análise Ambiental pelo Instituto de Geociências da Universidade de Brasília), UNB, Brasília-DF, 2003.

SILVA, N. C.; CARVALHO JÚNIOR, O. A.; SANTA ROSA, A. N. C.; GUIMARÃES, R. F.; GOMES, R.A.T. 2012. Programa para detecção de mudança usando Mapas Auto-Organizáveis.

Revista Brasileira de Geofísica. v. 30, p. 147-157 2. Rio de Janeiro - RJ, 2012.

TAFNER, M. A.; de XEREZ, M.; FILHO, I. W. R. **Redes neurais artificiais:** introdução e princípios de neurocomputação. Editoras ECO e Editora da FURB, Blumenau, 1996.

TODT, V. **Avaliação do desempenho de classificadores neurais para aplicações em sensoriamento remoto.** 1998. 161f. Dissertação (Mestrado em Sensoriamento Remoto). Universidade Federal do Rio Grande do Sul. Porto Alegre – RS, 1998.

UNICA – União da Indústria de Cana-de-Açúcar. **Agroindústria da cana-de-açúcar:** alta competitividade canavieira – a alta competitividade canavieira em São Paulo. 2006. Disponível em: <http://www.unica.com.br/pages/agroindustria_alta.asp>. Acesso em: 20 set. 2012.

UNIVERSIDADE DE SÃO PAULO. **Relatórios Técnicos do Instituto de Ciências Matemáticas e de Computação:** Estudo e Análise das Diversas Representações e Estruturas de Dados Utilizadas nos Algoritmos de Clustering Hierárquicos, 2006. São Paulo: São Carlos, 2006, 48p.

WADSWORTH, Harrison M.; STEPHENS, Kenneth S.; GODFREY, A. Blanton. **Modern Methods for Quality Control and Improvement.** EUA: John Wiley, 1986, 690 p.

WETMORE, L.; HEYWOOD, M. I.; ZINCIR-HEYWOOD, A. N. “**Speeding up the Self Organizing Feature Map Using Dynamic Subset Selection**”, Neural Processing Letters, 22, pp. 17-32, 2005.

WETMORE, L.; ZINCIR-HEYWOOD, A. N.; HEYWOOD, M. I. “**Training the SOM Efficiently: An Example from Intrusion Detection**”, Proceedings of the IEEE IJCNN 2005 – International Joint Conference on Neural Networks, pp. 1575-1580, 2005.

ANEXOS

Anexo 1 – Produção de cana-de-açúcar em hectares referentes aos 246 municípios do Estado de Goiás, coletados a partir do Banco de Dados Agregados – Sistema IBGE de Recuperação Automática (SIDRA).

GEOCOD	Cidade	UF	Cana_1995	Cana_2010
5200050	Abadia de Goiás	GO	0	0
5200100	Abadiânia	GO	5	20
5200134	Acreúna	GO	2300	13400
5200159	Adelândia	GO	0	0
5200175	Água Fria de Goiás	GO	80	24
5200209	Água Limpa	GO	100	0
5200258	Águas Lindas de Goiás	GO	0	0
5200308	Alexânia	GO	150	200
5200506	Aloândia	GO	0	0
5200555	Alto Horizonte	GO	15	10
5200605	Alto Paraíso de Goiás	GO	100	20
5200803	Alvorada do Norte	GO	55	70
5200829	Amaralina	GO	0	10
5200852	Americano do Brasil	GO	1040	2200
5200902	Amorinópolis	GO	25	10
5201108	Anápolis	GO	20	40
5201207	Ananguera	GO	0	30
5201306	Anicuns	GO	2572	12100
5201405	Aparecida de Goiânia	GO	32	5
5201454	Aparecida do Rio Doce	GO	0	558
5201504	Aporé	GO	10	3668
5201603	Araçu	GO	183	827
5201702	Aragarças	GO	0	0
5201801	Aragoiânia	GO	20	30
5202155	Araguapaz	GO	15	20
5202353	Arenópolis	GO	20	20
5202502	Aruanã	GO	0	0
5202601	Aurilândia	GO	0	0
5202809	Avelinópolis	GO	0	827
5203104	Baliza	GO	0	0
5203203	Barro Alto	GO	900	5500
5203302	Bela Vista de Goiás	GO	190	10
5203401	Bom Jardim de Goiás	GO	40	100
5203500	Bom Jesus de Goiás	GO	2030	22000
5203559	Bonfinópolis	GO	0	0
5203575	Bonópolis	GO	0	20
5203609	Brazabrantes	GO	1396	651
5203807	Britânia	GO	0	0
5203906	Buriti Alegre	GO	0	700
5203939	Buriti de Goiás	GO	0	0
5203962	Buritinópolis	GO	40	32
5204003	Cabeceiras	GO	45	40

5204102	Cachoeira Alta	GO	0	2500
5204201	Cachoeira de Goiás	GO	0	0
5204250	Cachoeira Dourada	GO	0	6000
5204300	Caçu	GO	0	7431
5204409	Caiapônia	GO	80	70
5204508	Caldas Novas	GO	0	0
5204557	Caldazinha	GO	30	20
5204607	Campestre de Goiás	GO	10	0
5204656	Campinaçu	GO	70	30
5204706	Campinorte	GO	0	160
5204805	Campo Alegre de Goiás	GO	2200	400
5204854	Campo Limpo de Goiás	GO	0	0
5204904	Campos Belos	GO	90	150
5204953	Campos Verdes	GO	5	3
5205000	Carmo do Rio Verde	GO	1580	4300
5205059	Castelândia	GO	838	3350
5205109	Catalão	GO	150	800
5205208	Caturai	GO	186	1742
5205307	Cavalcante	GO	150	50
5205406	Ceres	GO	1800	500
5205455	Cezarina	GO	25	10
5205471	Chapadão do Céu	GO	15	21035
5205497	Cidade Ocidental	GO	75	40
5205513	Cocalzinho de Goiás	GO	0	40
5205521	Colinas do Sul	GO	50	10
5205703	Córrego do Ouro	GO	25	35
5205802	Corumbá de Goiás	GO	120	80
5205901	Corumbáiba	GO	180	20
5206206	Cristalina	GO	100	420
5206305	Cristianópolis	GO	0	10
5206404	Crixás	GO	30	15
5206503	Cromínia	GO	0	0
5206602	Cumari	GO	0	50
5206701	Damianópolis	GO	80	145
5206800	Damolândia	GO	19	28
5206909	Davinópolis	GO	0	40
5207105	Diorama	GO	25	6
5207253	Doverlândia	GO	45	660
5207352	Edealina	GO	0	0
5207402	Edéia	GO	0	13088
5207501	Estrela do Norte	GO	45	100
5207535	Faina	GO	0	15
5207600	Fazenda Nova	GO	0	0
5207808	Firminópolis	GO	0	0
5207907	Flores de Goiás	GO	30	14
5208004	Formosa	GO	160	180
5208103	Formoso	GO	60	10
5208152	Gameleira de Goiás	GO	0	25

5208301	Divinópolis de Goiás	GO	50	190
5208400	Goianápolis	GO	5	0
5208509	Goianira	GO	100	40
5208608	Goianésia	GO	14500	13500
5208707	Goiânia	GO	0	50
5208806	Goianira	GO	156	953
5208905	Goiás	GO	0	120
5209101	Goiatuba	GO	10850	20000
5209150	Gouvelândia	GO	0	18800
5209200	Guapó	GO	40	15
5209291	Guaraíta	GO	0	0
5209408	Guarani de Goiás	GO	50	80
5209457	Guarinos	GO	40	30
5209606	Heitorai	GO	10	825
5209705	Hidrolândia	GO	75	20
5209804	Hidrolina	GO	35	1500
5209903	Iaciara	GO	50	80
5209937	Inaciolândia	GO	90	4770
5209952	Indiara	GO	1730	4897
5210000	Inhumas	GO	2738	6430
5210109	Ipameri	GO	4000	4800
5210158	Ipiranga de Goiás	GO	0	2300
5210208	Iporá	GO	60	10
5210307	Israelândia	GO	20	5
5210406	Itaberaí	GO	890	8515
5210562	Itaguari	GO	0	28
5210604	Itaguaru	GO	0	0
5210802	Itajá	GO	12	0
5210901	Itapaci	GO	20	4000
5211008	Itapirapuã	GO	0	0
5211206	Itapuranga	GO	0	3415
5211305	Itarumã	GO	0	3315
5211404	Itauçu	GO	96	794
5211503	Itumbiara	GO	5557	21800
5211602	Ivolândia	GO	30	5
5211701	Jandaia	GO	3699	11074
5211800	Jaraguá	GO	0	0
5211909	Jataí	GO	880	18000
5212006	Jaupaci	GO	16	0
5212055	Jesópolis	GO	672	0
5212105	Joviânia	GO	0	201
5212204	Jussara	GO	55	40
5212253	Lagoa Santa	GO	0	0
5212303	Leopoldo de Bulhões	GO	20	25
5212501	Luziânia	GO	1000	180
5212600	Mairipotaba	GO	0	0
5212709	Mambaí	GO	70	60
5212808	Mara Rosa	GO	30	15

5212907	Marzagão	GO	0	0
5212956	Matrinchã	GO	0	0
5213004	Maurilândia	GO	3016	10440
5213053	Mimoso de Goiás	GO	50	15
5213087	Minaçu	GO	65	10
5213103	Mineiros	GO	65	22260
5213400	Moiporá	GO	13	0
5213509	Monte Alegre de Goiás	GO	110	110
5213707	Montes Claros de Goiás	GO	0	24
5213756	Montividiu	GO	0	11500
5213772	Montividiu do Norte	GO	50	0
5213806	Morrinhos	GO	92	14700
5213855	Morro Agudo de Goiás	GO	15	100
5213905	Mossâmedes	GO	0	735
5214002	Mozarlândia	GO	0	0
5214051	Mundo Novo	GO	0	60
5214101	Mutunópolis	GO	50	10
5214408	Nazário	GO	0	2316
5214507	Nerópolis	GO	0	0
5214606	Niquelândia	GO	70	65
5214705	Nova América	GO	23	300
5214804	Nova Aurora	GO	370	120
5214838	Nova Crixás	GO	0	0
5214861	Nova Glória	GO	1864	6500
5214879	Nova Iguaçu de Goiás	GO	15	5
5214903	Nova Roma	GO	150	220
5215009	Nova Veneza	GO	135	225
5215207	Novo Brasil	GO	0	15
5215231	Novo Gama	GO	0	25
5215256	Novo Planalto	GO	40	10
5215306	Orizona	GO	200	300
5215405	Ouro Verde de Goiás	GO	6	20
5215504	Ouvidor	GO	0	30
5215603	Padre Bernardo	GO	180	90
5215652	Palestina de Goiás	GO	0	0
5215702	Palmeiras de Goiás	GO	110	446
5215801	Palmelo	GO	0	0
5215900	Palminópolis	GO	30	110
5216007	Panamá	GO	430	1000
5216304	Paranaiguara	GO	0	9900
5216403	Paraúna	GO	60	7550
5216452	Perolândia	GO	0	2165
5216809	Petrolina de Goiás	GO	260	0
5216908	Pilar de Goiás	GO	30	20
5217104	Piracanjuba	GO	60	0
5217203	Piranhas	GO	40	18
5217302	Pirenópolis	GO	2400	0
5217401	Pires do Rio	GO	25	0

5217609	Planaltina	GO	100	36
5217708	Pontalina	GO	0	3500
5218003	Porangatu	GO	30	20
5218052	Porteirão	GO	0	25140
5218102	Portelândia	GO	8	850
5218300	Posse	GO	160	200
5218391	Professor Jamil	GO	0	0
5218508	Quirinópolis	GO	0	43200
5218607	Rialma	GO	0	3000
5218706	Rianópolis	GO	0	1300
5218789	Rio Quente	GO	0	0
5218805	Rio Verde	GO	1450	10500
5218904	Rubiataba	GO	0	6561
5219001	Sanclerlândia	GO	0	45
5219100	Santa Bárbara de Goiás	GO	5	232
5219209	Santa Cruz de Goiás	GO	0	100
5219258	Santa Fé de Goiás	GO	15	20
5219308	Santa Helena de Goiás	GO	12723	35640
5219357	Santa Isabel	GO	0	3100
5219407	Santa Rita do Araguaia	GO	8	0
5219456	Santa Rita do Novo Destino	GO	0	3040
5219506	Santa Rosa de Goiás	GO	0	0
5219605	Santa Tereza de Goiás	GO	55	10
5219704	Santa Terezinha de Goiás	GO	20	8
5219712	Santo Antônio da Barra	GO	0	3540
5219738	Santo Antônio de Goiás	GO	214	965
5219753	Santo Antônio do Descoberto	GO	100	30
5219803	São Domingos	GO	60	100
5219902	São Francisco de Goiás	GO	2020	0
5220009	São João d'Aliança	GO	170	70
5220058	São João da Paraúna	GO	0	0
5220108	São Luís de Montes Belos	GO	0	0
5220157	São Luíz do Norte	GO	45	9000
5220207	São Miguel do Araguaia	GO	35	10
5220264	São Miguel do Passa Quatro	GO	0	20
5220280	São Patrício	GO	0	1300
5220405	São Simão	GO	0	3460
5220454	Senador Canedo	GO	43	43
5220504	Serranópolis	GO	7618	10771
5220603	Silvânia	GO	120	240
5220686	Simolândia	GO	0	60
5220702	Sítio d'Abadia	GO	87	98
5221007	Taquaral de Goiás	GO	0	193
5221080	Teresina de Goiás	GO	30	12
5221197	Terezópolis de Goiás	GO	0	0
5221304	Três Ranchos	GO	0	40
5221403	Trindade	GO	475	274
5221452	Trombas	GO	35	10

5221502	Turvânia	GO	0	3000
5221551	Turvelândia	GO	11581	12000
5221577	Uirapuru	GO	15	6
5221601	Uruaçu	GO	75	2700
5221700	Uruana	GO	0	1500
5221809	Urutaí	GO	300	0
5221858	Valparaíso de Goiás	GO	0	0
5221908	Varjão	GO	40	60
5222005	Vianópolis	GO	80	30
5222054	Vicentinópolis	GO	0	1000
5222203	Vila Boa	GO	30	4612
5222302	Vila Propício	GO	0	18000

Anexo 2 – Produção do rebanho bovino de corte em número de cabeças referentes aos 246 municípios do Estado de Goiás, coletados a partir do Banco de Dados Agregados – Sistema IBGE de Recuperação Automática (SIDRA).

GEOCOD	Cidade	UF	Rebanho 1995	Rebanho 2010
5200050	Abadia de Goiás	GO	0	16400
5200100	Abadiânia	GO	39100	45000
5200134	Acreúna	GO	115000	88000
5200159	Adelândia	GO	12740	14500
5200175	Água Fria de Goiás	GO	52100	45448
5200209	Água Limpa	GO	46540	59000
5200258	Águas Lindas de Goiás	GO	0	4700
5200308	Alexânia	GO	36000	45000
5200506	Aloândia	GO	15000	17100
5200555	Alto Horizonte	GO	40000	44000
5200605	Alto Paraíso de Goiás	GO	13700	33409
5200803	Alvorada do Norte	GO	32625	45000
5200829	Amaralina	GO	0	84000
5200852	Americano do Brasil	GO	17490	21500
5200902	Amorinópolis	GO	39000	54900
5201108	Anápolis	GO	82700	74000
5201207	Anhanguera	GO	3760	4700
5201306	Anicuns	GO	94210	113000
5201405	Aparecida de Goiânia	GO	10000	10030
5201454	Aparecida do Rio Doce	GO	64000	60390
5201504	Aporé	GO	185000	198000
5201603	Araçu	GO	23800	20000
5201702	Aragarças	GO	24000	29200
5201801	Aragoiânia	GO	20500	19000
5202155	Araguapaz	GO	170000	185400
5202353	Arenópolis	GO	80000	100900
5202502	Aruanã	GO	195000	266935
5202601	Aurilândia	GO	51000	68500

5202809	Avelinópolis	GO	21890	27200
5203104	Baliza	GO	46000	67600
5203203	Barro Alto	GO	90000	47250
5203302	Bela Vista de Goiás	GO	112000	128120
5203401	Bom Jardim de Goiás	GO	91000	155700
5203500	Bom Jesus de Goiás	GO	100000	65800
5203559	Bonfinópolis	GO	7700	10200
5203575	Bonópolis	GO	0	130000
5203609	Brazabrantes	GO	13200	14800
5203807	Britânia	GO	91450	161750
5203906	Buriti Alegre	GO	68900	86900
5203939	Buriti de Goiás	GO	33850	26150
5203962	Buritinópolis	GO	9762	17000
5204003	Cabeceiras	GO	49000	33960
5204102	Cachoeira Alta	GO	140000	150000
5204201	Cachoeira de Goiás	GO	26300	24900
5204250	Cachoeira Dourada	GO	37800	31300
5204300	Caçu	GO	170000	189840
5204409	Caiapônia	GO	371000	407200
5204508	Caldas Novas	GO	66630	100000
5204557	Caldazinha	GO	10000	23400
5204607	Campestre de Goiás	GO	41000	26300
5204656	Campinaçu	GO	46000	70100
5204706	Campinorte	GO	30000	43500
5204805	Campo Alegre de Goiás	GO	48500	70500
5204854	Campo Limpo de Goiás	GO	0	15000
5204904	Campos Belos	GO	41490	60500
5204953	Campos Verdes	GO	6200	38000
5205000	Carmo do Rio Verde	GO	48000	34000
5205059	Castelândia	GO	30000	15000
5205109	Catalão	GO	127500	173000
5205208	Caturai	GO	23850	22300
5205307	Cavalcante	GO	44000	60162
5205406	Ceres	GO	45000	23500
5205455	Cezarina	GO	24800	45500
5205471	Chapadão do Céu	GO	32500	18600
5205497	Cidade Ocidental	GO	20000	17850
5205513	Cocalzinho de Goiás	GO	69000	88000
5205521	Colinas do Sul	GO	14000	26000
5205703	Córrego do Ouro	GO	45000	70922
5205802	Corumbá de Goiás	GO	46000	56000
5205901	Corumbamba	GO	98980	154500
5206206	Cristalina	GO	140000	150400
5206305	Cristianópolis	GO	13500	16000
5206404	Crixás	GO	100000	215000
5206503	Cromínia	GO	33000	34000
5206602	Cumari	GO	37000	68500
5206701	Damianópolis	GO	14500	22550

5206800	Damolândia	GO	11700	14000
5206909	Davinópolis	GO	20500	33200
5207105	Diorama	GO	47000	67900
5207253	Doverlândia	GO	230000	275830
5207352	Edealina	GO	53000	65000
5207402	Edéia	GO	107600	81550
5207501	Estrela do Norte	GO	24000	23100
5207535	Faina	GO	310000	153925
5207600	Fazenda Nova	GO	115000	123000
5207808	Firminópolis	GO	56000	51300
5207907	Flores de Goiás	GO	123000	133827
5208004	Formosa	GO	188000	228010
5208103	Formoso	GO	31500	55000
5208152	Gameleira de Goiás	GO	0	21800
5208301	Divinópolis de Goiás	GO	32617	50000
5208400	Goianápolis	GO	17600	13000
5208509	Goiandira	GO	29000	52000
5208608	Goianésia	GO	106000	110000
5208707	Goiânia	GO	65000	27700
5208806	Goianira	GO	10200	21000
5208905	Goiás	GO	250000	257730
5209101	Goiatuba	GO	176500	110600
5209150	Gouvelândia	GO	50000	50300
5209200	Guapó	GO	58000	60010
5209291	Guaraíta	GO	44500	21200
5209408	Guarani de Goiás	GO	29758	51000
5209457	Guarinos	GO	19500	32500
5209606	Heitorai	GO	27260	28000
5209705	Hidrolândia	GO	71000	77500
5209804	Hidrolina	GO	40000	43000
5209903	Iaciara	GO	61500	134000
5209937	Inaciolândia	GO	46000	50600
5209952	Indiara	GO	88320	80050
5210000	Inhumas	GO	61000	71500
5210109	Ipameri	GO	99000	195000
5210158	Ipiranga de Goiás	GO	0	22300
5210208	Iporá	GO	88000	104600
5210307	Israelândia	GO	48000	49600
5210406	Itaberaí	GO	152730	141000
5210562	Itaguari	GO	17960	19300
5210604	Itaguaru	GO	28230	26200
5210802	Itajá	GO	207000	174290
5210901	Itapaci	GO	51000	78300
5211008	Itapirapuã	GO	350000	263500
5211206	Itapuranga	GO	106000	130400
5211305	Itarumã	GO	297000	290600
5211404	Itauçu	GO	46950	48500
5211503	Itumbiara	GO	180000	164200

5211602	Ivolândia	GO	66000	104000
5211701	Jandaia	GO	71280	84000
5211800	Jaraguá	GO	120500	158250
5211909	Jataí	GO	430000	321770
5212006	Jaupaci	GO	37500	41300
5212055	Jesúpolis	GO	9000	12100
5212105	Joviânia	GO	53000	34500
5212204	Jussara	GO	450000	394569
5212253	Lagoa Santa	GO	0	46530
5212303	Leopoldo de Bulhões	GO	33600	38000
5212501	Luziânia	GO	139000	172000
5212600	Mairipotaba	GO	34500	44000
5212709	Mambaí	GO	6530	7000
5212808	Mara Rosa	GO	130000	148000
5212907	Marzagão	GO	10680	23500
5212956	Matrinchã	GO	120000	124185
5213004	Maurilândia	GO	40000	23500
5213053	Mimoso de Goiás	GO	40000	52500
5213087	Minaçu	GO	63500	98000
5213103	Mineiros	GO	302000	307000
5213400	Moiporá	GO	39000	46300
5213509	Monte Alegre de Goiás	GO	70000	127000
5213707	Montes Claros de Goiás	GO	260000	290500
5213756	Montividiu	GO	70000	50600
5213772	Montividiu do Norte	GO	46000	80000
5213806	Morrinhos	GO	204280	295000
5213855	Morro Agudo de Goiás	GO	20500	32400
5213905	Mossâmedes	GO	76500	91435
5214002	Mozarlândia	GO	181700	180540
5214051	Mundo Novo	GO	190000	208160
5214101	Mutunópolis	GO	50000	75000
5214408	Nazário	GO	33730	36500
5214507	Nerópolis	GO	20000	22500
5214606	Niquelândia	GO	145000	235000
5214705	Nova América	GO	16000	23750
5214804	Nova Aurora	GO	18000	31500
5214838	Nova Crixás	GO	435000	744960
5214861	Nova Glória	GO	18500	26700
5214879	Nova Iguaçu de Goiás	GO	30000	37000
5214903	Nova Roma	GO	32900	70000
5215009	Nova Veneza	GO	12300	20200
5215207	Novo Brasil	GO	118600	95795
5215231	Novo Gama	GO	0	4890
5215256	Novo Planalto	GO	56000	90000
5215306	Orizona	GO	87000	153000
5215405	Ouro Verde de Goiás	GO	13500	31500
5215504	Ouvidor	GO	16000	28500
5215603	Padre Bernardo	GO	110000	125300

5215652	Palestina de Goiás	GO	116000	100390
5215702	Palmeiras de Goiás	GO	124800	156300
5215801	Palmelo	GO	2600	3200
5215900	Palminópolis	GO	37000	50770
5216007	Panamá	GO	22000	33600
5216304	Paranaiguara	GO	80000	89600
5216403	Paraúna	GO	212720	188800
5216452	Perolândia	GO	31000	24000
5216809	Petrolina de Goiás	GO	57500	75000
5216908	Pilar de Goiás	GO	45000	76000
5217104	Piracanjuba	GO	215850	215000
5217203	Piranhas	GO	138000	216000
5217302	Pirenópolis	GO	189200	144500
5217401	Pires do Rio	GO	62500	91500
5217609	Planaltina	GO	42500	77919
5217708	Pontalina	GO	129200	142500
5218003	Porangatu	GO	272000	340000
5218052	Porteirão	GO	0	23500
5218102	Portelândia	GO	32000	22780
5218300	Posse	GO	55185	108000
5218391	Professor Jamil	GO	38980	42000
5218508	Quirinópolis	GO	380000	330000
5218607	Rialma	GO	32000	22200
5218706	Rianópolis	GO	17000	15400
5218789	Rio Quente	GO	8110	21500
5218805	Rio Verde	GO	500000	400000
5218904	Rubiataba	GO	58000	75500
5219001	Sanclerlândia	GO	94250	80395
5219100	Santa Bárbara de Goiás	GO	21200	19200
5219209	Santa Cruz de Goiás	GO	40500	72500
5219258	Santa Fé de Goiás	GO	160100	132145
5219308	Santa Helena de Goiás	GO	70000	54800
5219357	Santa Isabel	GO	60000	61300
5219407	Santa Rita do Araguaia	GO	70000	61950
5219456	Santa Rita do Novo Destino	GO	0	49800
5219506	Santa Rosa de Goiás	GO	21000	25810
5219605	Santa Tereza de Goiás	GO	39000	52000
5219704	Santa Terezinha de Goiás	GO	50000	92000
5219712	Santo Antônio da Barra	GO	37000	31500
5219738	Santo Antônio de Goiás	GO	17500	15900
5219753	Santo Antônio do Descoberto	GO	37000	32400
5219803	São Domingos	GO	100212	139000
5219902	São Francisco de Goiás	GO	23000	38700
5220009	São João d'Aliança	GO	70000	65961
5220058	São João da Paraúna	GO	29900	28090
5220108	São Luís de Montes Belos	GO	120000	114000
5220157	São Luíz do Norte	GO	55000	24000
5220207	São Miguel do Araguaia	GO	318000	570000

5220264	São Miguel do Passa Quatro	GO	27800	33000
5220280	São Patrício	GO	0	17050
5220405	São Simão	GO	30000	31200
5220454	Senador Canedo	GO	15500	18690
5220504	Serranópolis	GO	250000	205410
5220603	Silvânia	GO	140000	103000
5220686	Simolândia	GO	11737	23000
5220702	Sítio d'Abadia	GO	14200	33000
5221007	Taquaral de Goiás	GO	17632	29000
5221080	Teresina de Goiás	GO	7500	8589
5221197	Terezópolis de Goiás	GO	12500	12000
5221304	Três Ranchos	GO	9700	17000
5221403	Trindade	GO	82500	73500
5221452	Trombas	GO	35000	42000
5221502	Turvânia	GO	60000	72200
5221551	Turvelândia	GO	30000	42600
5221577	Uirapuru	GO	43000	86000
5221601	Uruaçu	GO	80000	112000
5221700	Uruana	GO	48000	55600
5221809	Urutaí	GO	36500	51500
5221858	Valparaíso de Goiás	GO	0	400
5221908	Varjão	GO	33350	47300
5222005	Vianópolis	GO	44500	54500
5222054	Vicentinópolis	GO	42000	34350
5222203	Vila Boa	GO	48000	44280
5222302	Vila Propício	GO	0	84880

Anexo 3 – Produção de leite em litros referentes aos 246 municípios do Estado de Goiás, coletados a partir do Banco de Dados Agregados – Sistema IBGE de Recuperação Automática (SIDRA).

GEOCOD	Cidade	UF	Leite 1995	Leite 2010
5200050	Abadia de Goiás	GO	0	2218
5200100	Abadiânia	GO	2958	9000
5200134	Acreúna	GO	6460	10280
5200159	Adelândia	GO	1204	4490
5200175	Água Fria de Goiás	GO	4722	4148
5200209	Água Limpa	GO	8772	11885
5200258	Águas Lindas de Goiás	GO	0	553
5200308	Alexânia	GO	2800	9900
5200506	Aloândia	GO	2800	2260
5200555	Alto Horizonte	GO	4860	9000
5200605	Alto Paraíso de Goiás	GO	316	1521
5200803	Alvorada do Norte	GO	90	1200
5200829	Amaralina	GO	0	12500
5200852	Americano do Brasil	GO	1163	7402
5200902	Amorinópolis	GO	4212	7900
5201108	Anápolis	GO	5280	13500

5201207	Anhanguera	GO	405	1404
5201306	Anicuns	GO	10756	38400
5201405	Aparecida de Goiânia	GO	560	3098
5201454	Aparecida do Rio Doce	GO	5512	2245
5201504	Aporé	GO	4900	2699
5201603	Araçu	GO	4020	3550
5201702	Aragarças	GO	1050	1850
5201801	Aragoiânia	GO	2830	4554
5202155	Araguapaz	GO	3730	8910
5202353	Arenópolis	GO	6360	9940
5202502	Aruanã	GO	3130	2904
5202601	Aurilândia	GO	6150	6850
5202809	Avelinópolis	GO	1913	13500
5203104	Baliza	GO	1950	3890
5203203	Barro Alto	GO	8000	5820
5203302	Bela Vista de Goiás	GO	13900	31330
5203401	Bom Jardim de Goiás	GO	3150	13260
5203500	Bom Jesus de Goiás	GO	9000	9420
5203559	Bonfinópolis	GO	1150	3650
5203575	Bonópolis	GO	0	8000
5203609	Brazabrantes	GO	2376	3100
5203807	Britânia	GO	2781	2998
5203906	Buriti Alegre	GO	5250	8910
5203939	Buriti de Goiás	GO	2272	5232
5203962	Buritinópolis	GO	90	595
5204003	Cabeceiras	GO	4301	4585
5204102	Cachoeira Alta	GO	15660	17600
5204201	Cachoeira de Goiás	GO	2750	2400
5204250	Cachoeira Dourada	GO	3606	6000
5204300	Caçu	GO	4990	25380
5204409	Caiapônia	GO	10500	22660
5204508	Caldas Novas	GO	14200	20400
5204557	Caldazinha	GO	1740	5029
5204607	Campestre de Goiás	GO	7380	11800
5204656	Campinaçu	GO	1400	6000
5204706	Campinorte	GO	3600	8400
5204805	Campo Alegre de Goiás	GO	3825	17000
5204854	Campo Limpo de Goiás	GO	0	3650
5204904	Campos Belos	GO	600	1818
5204953	Campos Verdes	GO	600	5500
5205000	Carmo do Rio Verde	GO	4570	7796
5205059	Castelândia	GO	2863	2800
5205109	Catalão	GO	14486	79380
5205208	Caturai	GO	3544	5850
5205307	Cavalcante	GO	935	1564
5205406	Ceres	GO	3970	8023
5205455	Cezarina	GO	3224	8170
5205471	Chapadão do Céu	GO	877	430

5205497	Cidade Ocidental	GO	1550	4350
5205513	Cocalzinho de Goiás	GO	5220	11500
5205521	Colinas do Sul	GO	300	3700
5205703	Córrego do Ouro	GO	6290	10716
5205802	Corumbá de Goiás	GO	3980	10200
5205901	Corumbaba	GO	7580	51330
5206206	Cristalina	GO	9850	19900
5206305	Cristianópolis	GO	1840	6300
5206404	Crixás	GO	3150	20700
5206503	Cromínia	GO	6951	8865
5206602	Cumari	GO	3089	26440
5206701	Damianópolis	GO	180	640
5206800	Damolândia	GO	1764	2600
5206909	Davinópolis	GO	1980	13600
5207105	Diorama	GO	3600	7100
5207253	Doverlândia	GO	8520	19180
5207352	Edealina	GO	16981	17202
5207402	Edéia	GO	12910	8552
5207501	Estrela do Norte	GO	685	2100
5207535	Faina	GO	6375	20322
5207600	Fazenda Nova	GO	10000	15800
5207808	Firminópolis	GO	5700	11500
5207907	Flores de Goiás	GO	2437	3346
5208004	Formosa	GO	17100	19840
5208103	Formoso	GO	800	4400
5208152	Gameleira de Goiás	GO	0	7650
5208301	Divinópolis de Goiás	GO	380	1642
5208400	Goianápolis	GO	1450	2300
5208509	Goianeira	GO	2350	11680
5208608	Goianésia	GO	9000	18750
5208707	Goiânia	GO	13200	4125
5208806	Goianira	GO	2275	3800
5208905	Goiás	GO	6000	27636
5209101	Goiatuba	GO	11500	31500
5209150	Gouvelândia	GO	6040	6100
5209200	Guapó	GO	4500	8448
5209291	Guaraíta	GO	3768	4806
5209408	Guarani de Goiás	GO	220	720
5209457	Guarinos	GO	1444	3640
5209606	Heitorai	GO	2790	3950
5209705	Hidrolândia	GO	8590	16841
5209804	Hidrolina	GO	5000	7800
5209903	Iaciara	GO	1100	720
5209937	Inaciolândia	GO	5506	9000
5209952	Indiara	GO	13392	9936
5210000	Inhumas	GO	10000	31450
5210109	Ipameri	GO	11178	62370
5210158	Ipiranga de Goiás	GO	0	6615

5210208	Iporá	GO	14607	21400
5210307	Israelândia	GO	2600	3950
5210406	Itaberaí	GO	15995	27000
5210562	Itaguari	GO	1419	7750
5210604	Itaguaru	GO	2363	5550
5210802	Itajá	GO	7800	6751
5210901	Itapaci	GO	5116	14946
5211008	Itapirapuã	GO	7800	22044
5211206	Itapuranga	GO	9270	27060
5211305	Itarumã	GO	14200	4972
5211404	Itauçu	GO	5780	16381
5211503	Itumbiara	GO	25041	37600
5211602	Ivolândia	GO	3450	9130
5211701	Jandaia	GO	9405	13574
5211800	Jaraguá	GO	11200	28000
5211909	Jataí	GO	42024	119256
5212006	Jaupaci	GO	3190	4100
5212055	Jesúpolis	GO	760	1820
5212105	Joviânia	GO	9400	6960
5212204	Jussara	GO	12400	25284
5212253	Lagoa Santa	GO	0	2123
5212303	Leopoldo de Bulhões	GO	5335	14000
5212501	Luziânia	GO	13500	68590
5212600	Mairipotaba	GO	5000	14319
5212709	Mambaí	GO	250	310
5212808	Mara Rosa	GO	14000	19800
5212907	Marzagão	GO	2318	6715
5212956	Matrinchã	GO	1850	9126
5213004	Maurilândia	GO	3685	5360
5213053	Mimoso de Goiás	GO	1800	2790
5213087	Minaçu	GO	1500	8300
5213103	Mineiros	GO	23450	58964
5213400	Moiporá	GO	2750	3400
5213509	Monte Alegre de Goiás	GO	900	2580
5213707	Montes Claros de Goiás	GO	8750	13550
5213756	Montividiu	GO	5940	8490
5213772	Montividiu do Norte	GO	1100	5700
5213806	Morrinhos	GO	41425	112007
5213855	Morro Agudo de Goiás	GO	2184	7300
5213905	Mossâmedes	GO	4860	14076
5214002	Mozarlândia	GO	4520	7843
5214051	Mundo Novo	GO	3822	5885
5214101	Mutunópolis	GO	1450	5500
5214408	Nazário	GO	3068	8975
5214507	Nerópolis	GO	2000	4300
5214606	Niquelândia	GO	15000	27000
5214705	Nova América	GO	1550	5658
5214804	Nova Aurora	GO	1458	6400

5214838	Nova Crixás	GO	6452	9072
5214861	Nova Glória	GO	1676	4200
5214879	Nova Iguaçu de Goiás	GO	3500	8200
5214903	Nova Roma	GO	143	502
5215009	Nova Veneza	GO	2539	3850
5215207	Novo Brasil	GO	3714	11226
5215231	Novo Gama	GO	0	1380
5215256	Novo Planalto	GO	1070	6000
5215306	Orizona	GO	11500	75000
5215405	Ouro Verde de Goiás	GO	1120	5250
5215504	Ouvidor	GO	1573	10800
5215603	Padre Bernardo	GO	7900	7817
5215652	Palestina de Goiás	GO	5450	5746
5215702	Palmeiras de Goiás	GO	19095	21808
5215801	Palmelo	GO	450	1500
5215900	Palminópolis	GO	5023	9563
5216007	Panamá	GO	3770	7300
5216304	Paranaiguara	GO	6098	10015
5216403	Paraúna	GO	25267	24669
5216452	Perolândia	GO	1250	3264
5216809	Petrolina de Goiás	GO	6100	16875
5216908	Pilar de Goiás	GO	2784	9790
5217104	Piracanjuba	GO	48670	114313
5217203	Piranhas	GO	9488	18640
5217302	Pirenópolis	GO	18000	32000
5217401	Pires do Rio	GO	8318	26800
5217609	Planaltina	GO	3408	4946
5217708	Pontalina	GO	25031	35832
5218003	Porangatu	GO	8680	18000
5218052	Porteirão	GO	0	5130
5218102	Portelândia	GO	3475	15706
5218300	Posse	GO	1100	2956
5218391	Professor Jamil	GO	10200	7404
5218508	Quirinópolis	GO	44640	52250
5218607	Rialma	GO	2498	2850
5218706	Rianópolis	GO	1451	2565
5218789	Rio Quente	GO	1671	3641
5218805	Rio Verde	GO	38100	78800
5218904	Rubiataba	GO	8190	18360
5219001	Sanclerlândia	GO	6880	9066
5219100	Santa Bárbara de Goiás	GO	2178	6800
5219209	Santa Cruz de Goiás	GO	6500	32000
5219258	Santa Fé de Goiás	GO	4400	6122
5219308	Santa Helena de Goiás	GO	8978	12170
5219357	Santa Isabel	GO	5562	9225
5219407	Santa Rita do Araguaia	GO	3441	4050
5219456	Santa Rita do Novo Destino	GO	0	6180
5219506	Santa Rosa de Goiás	GO	1750	4000

5219605	Santa Tereza de Goiás	GO	1300	5000
5219704	Santa Terezinha de Goiás	GO	4350	15500
5219712	Santo Antônio da Barra	GO	5000	7650
5219738	Santo Antônio de Goiás	GO	3929	10000
5219753	Santo Antônio do Descoberto	GO	1800	2480
5219803	São Domingos	GO	700	2900
5219902	São Francisco de Goiás	GO	2000	6200
5220009	São João d'Aliança	GO	2240	2459
5220058	São João da Paraúna	GO	4674	4378
5220108	São Luís de Montes Belos	GO	15000	14950
5220157	São Luíz do Norte	GO	4800	3400
5220207	São Miguel do Araguaia	GO	2750	29000
5220264	São Miguel do Passa Quatro	GO	4500	13800
5220280	São Patrício	GO	0	5040
5220405	São Simão	GO	2700	3720
5220454	Senador Canedo	GO	810	3234
5220504	Serranópolis	GO	10700	9189
5220603	Silvânia	GO	22300	46500
5220686	Simolândia	GO	85	900
5220702	Sítio d'Abadia	GO	130	610
5221007	Taquaral de Goiás	GO	1720	14200
5221080	Teresina de Goiás	GO	200	391
5221197	Terezópolis de Goiás	GO	1152	2180
5221304	Três Ranchos	GO	1010	5100
5221403	Trindade	GO	15345	50010
5221452	Trombas	GO	800	3000
5221502	Turvânia	GO	6300	9000
5221551	Turvelândia	GO	2890	4950
5221577	Uirapuru	GO	1300	6250
5221601	Uruaçu	GO	13000	20500
5221700	Uruana	GO	4897	14820
5221809	Urutaí	GO	5100	14500
5221858	Valparaíso de Goiás	GO	0	144
5221908	Varjão	GO	4760	6937
5222005	Vianópolis	GO	6956	18900
5222054	Vicentinópolis	GO	9000	8150
5222203	Vila Boa	GO	4585	3607
5222302	Vila Propício	GO	0	10200

APÊNDICES

APÊNDICE A – Algoritmos (códigos) utilizados no MATLAB

1º TRANSFORMA

```
%TRANSFORMA Transforma os dados tabulares gerados pelo DMB-SOM em dados matriciais
%
%
%[MPesos, MQtde] = Transforma(pRede)
%
%Parâmetros de Entrada:
%  pRede: Matriz [Nx4] de pesos da camada de saída de uma rede SOM
%  pRede(:,1): Índice da linha do neurônio de uma rede SOM
%  pRede(:,2): Índice da coluna do neurônio de uma rede SOM
%  pRede(:,3): Quantidade de amostras classificadas pelo neurônio
%  pRede(:,4): Valor de peso do neurônio (centróide)
%  N = LxC.
%
%Parâmetros de Saída:
%  MPesos: Matriz [LxC] de pesos da camada de saída de uma rede SOM
%  MQtde: Matriz [LxC] com quantidades de amostras classificadas por cada neurônio de saída
%
%
%Direitos Autorais (2013):
%  Eude de Sousa Campos
%  Nilton Correia da Silva
%
```

```
function [MPesos, MQtde] = Transforma(pRede)
    [pqtlin px] = size(pRede);
    MPesos = zeros(max(pRede(:,1)), max(pRede(:,2)));
    MQtde = zeros(max(pRede(:,1)), max(pRede(:,2)));
    for pl = 1:pqtlin
        MPesos(pRede(pl,1), pRede(pl,2)) = pRede(pl,4);
        MQtde(pRede(pl,1), pRede(pl,2)) = pRede(pl,3);
    end
```

2º VISUREDE

```
%VISUREDE Visualização em 3D de pesos e distribuição de amostras de uma
%  rede neural SOM.
%
%VisuRede(pPesos, pQt, paz, pel, plimZ)
%
%Parâmetros de Entrada:
%  pPesos: Matriz [LxC] de pesos da camada de saída de uma rede SOM
%  pQt: Matriz [LxC] com quantidades de amostras classificadas por cada
%  neurônio de saída.
```

```

% paz: Ângulo de azimute dos gráficos 3D
% pel: Ângulo de elevação dos gráficos 3D
% plimZ: Vetor[2] contendo os valores máximos do eixo Z dos gráficos 3D.
%
%Direitos Autorais (2013):
% Eude de Sousa Campos
% Nilton Correia da Silva
%

function VisuRede(pPesos, pQt, paz, pel, plimZ)
%paz = -37.5;
%pel = 30;
[pqmlin pqmcol] = size(pPesos);
figure;
%Plotando pesos da rede:
subplot(1,2,1);
[x,y] = meshgrid([1:1:pqmlin]);
surf(x, y, pPesos); %(pPesos, []);
xlim([1 pqmlin]);
ylim([1 pqmcol]);
zlim([0 plimZ(1,1)]);
title(['Rede SOM ',num2str(pqmlin),'x', num2str(pqmcol)]);
view(paz, pel);
colormap(pink);

%Plotando distribuição por grupo
subplot(1,2,2);
surf(x, y, pQt);
xlim([1 pqmlin]);
ylim([1 pqmcol]);
zlim([0 plimZ(1,2)]);
title('Distribuição Por Grupo');
view(paz, pel);
colormap(pink);
%Voltar intervalo do eixo Z para automático:
%zlim('auto');
end

```

3º IMPORTADADOS

```

%IMPORTADADOS Script para importação de dados tabulares gerados pelo DMB-SOM.
%
%
%Direitos Autorais (2013):
% Eude de Sousa Campos
% Nilton Correia da Silva
%

%Script para:

```



```

%Importação dos dados do formato original para formato matricial LxC
%Lembrete: Altere o nome das var. de saída conforme o caso:
[Som, Qtde] = Transforma(data);

%Contagem de neurônios ativos e inativos:
[QtLin QtCol] = size(Qtde);
QtNeuronios = QtLin*QtCol
QtInativos = sum(sum(Qtde==0))
QtAtivos = QtNeuronios - QtInativos

%Visualização em 3D:

VisuRede(Som, Qtde, -37.5, 30, [570000 350]);

```

4º SOMCOR

```

function pmap = somcor(ppesos, pativacao)
%UNTITLED Summary of this function goes here
% Detailed explanation goes here
%Maps de cores

pintervalo = [min(min(ppesos)) max(max(ppesos))];
%pativacao(pativacao>0) = 1;
%ppesos(pativacao<=0) = -100;
%pimg = ppesos.*pativacao;
h = axes; %figure;
% imagesc(pimg, [0 255]);
pmap = pimg;
colormap(pmap);
imagesc(ppesos,[pintervalo(1) pintervalo(2)]);
set(h,'XAxisLocation','top');
xlabel('Coluna');
ylabel('Linha');

% image(pimg);
pmap = pmap.*255;

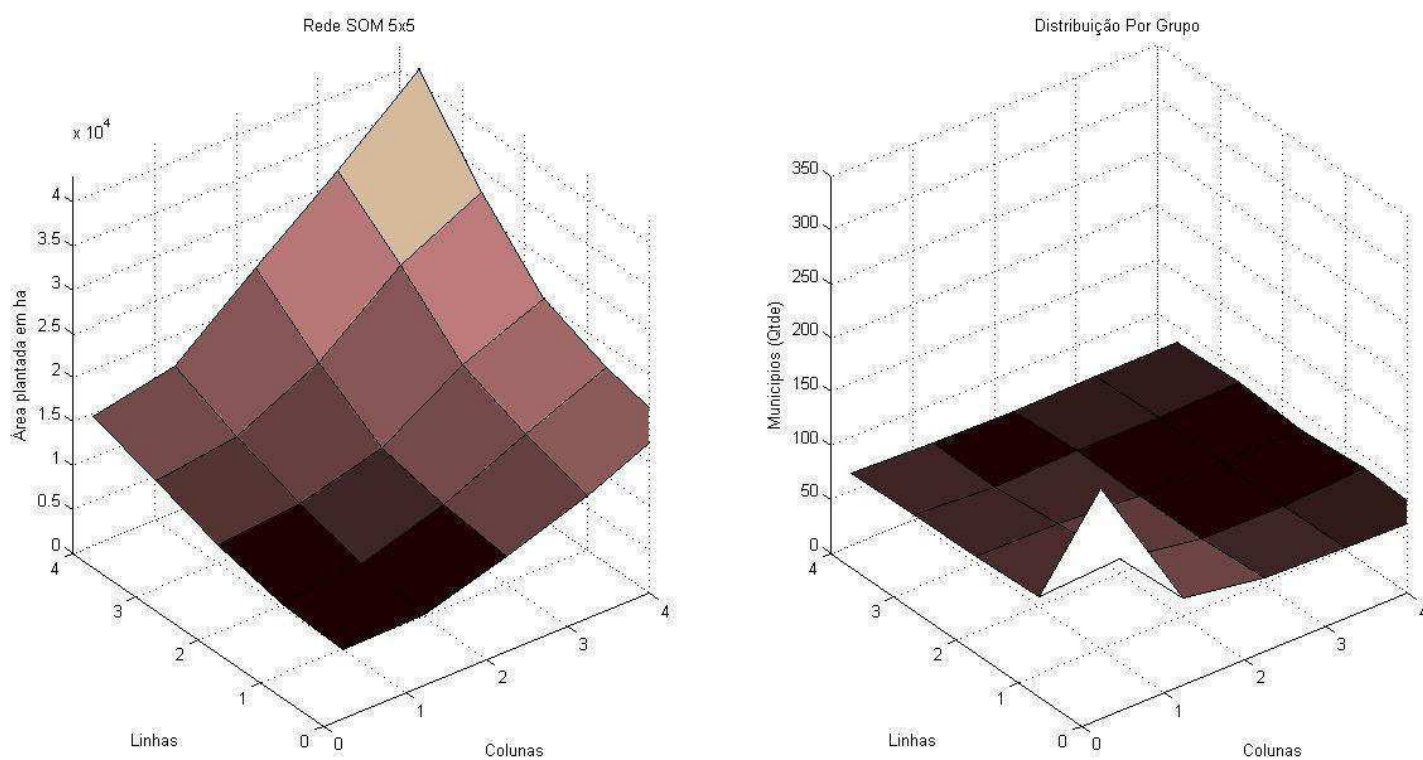
end

```

APÊNDICE B – Comportamento da Rede SOFM e Distribuição por Grupo

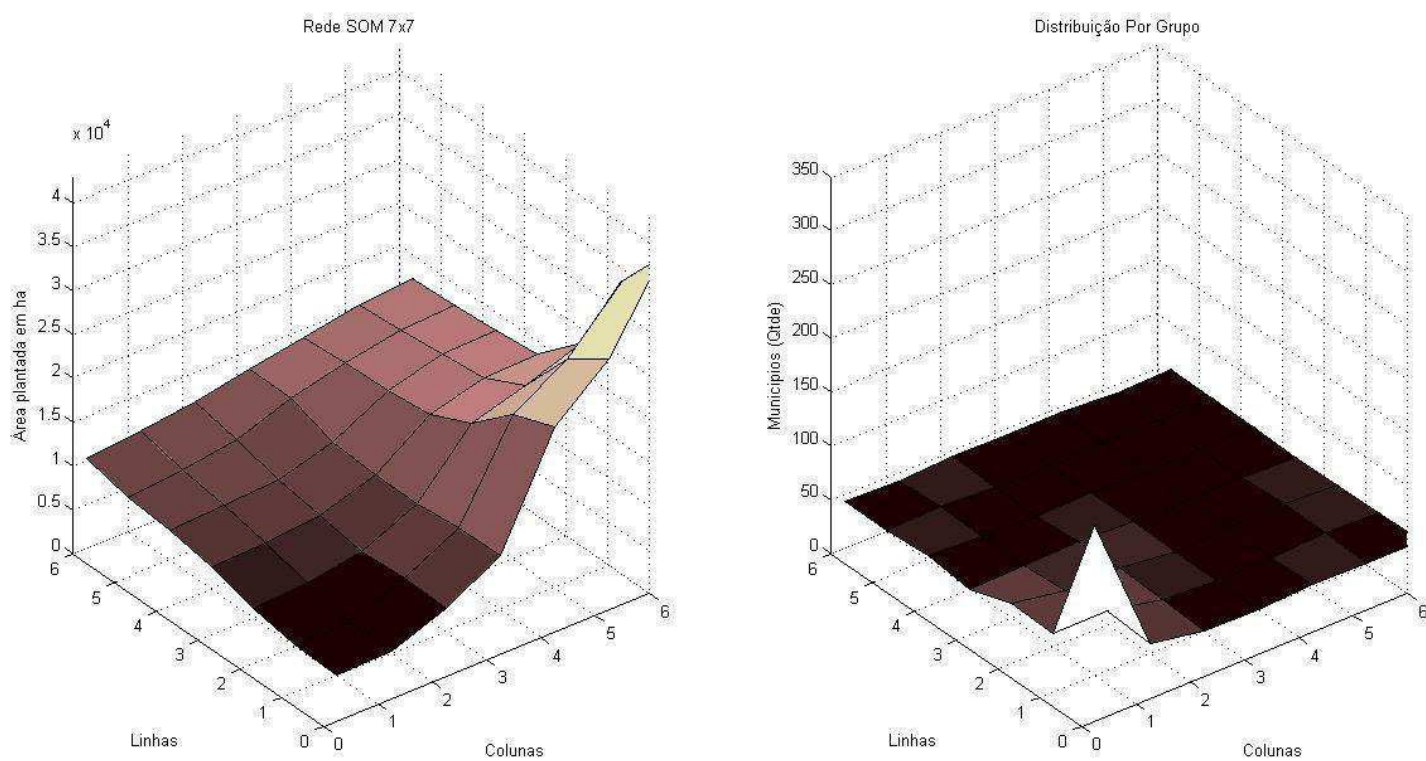
B.1 – Área plantada de cana-de-açúcar em hectares (ha)

Figura 34: A esquerda Rede SOFM 5 x 5 (classificação relativa a produtividade); a direita Distribuição por Grupo (Quantitativo de municípios classificados).



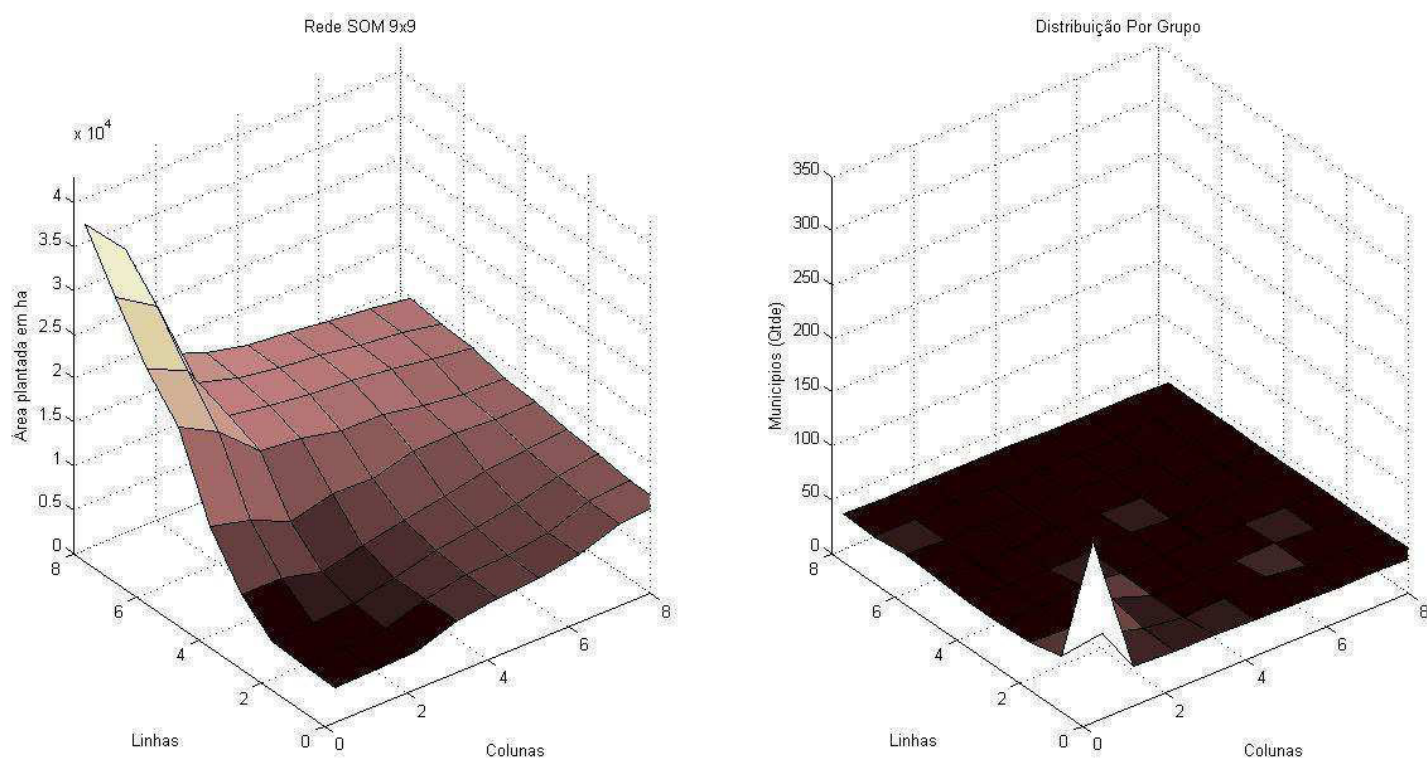
Fonte: Autor (2013).

Figura 35: A esquerda Rede SOFM 7 x 7 (classificação relativa a produtividade); a direita Distribuição por Grupo (Quantitativo de municípios classificados).



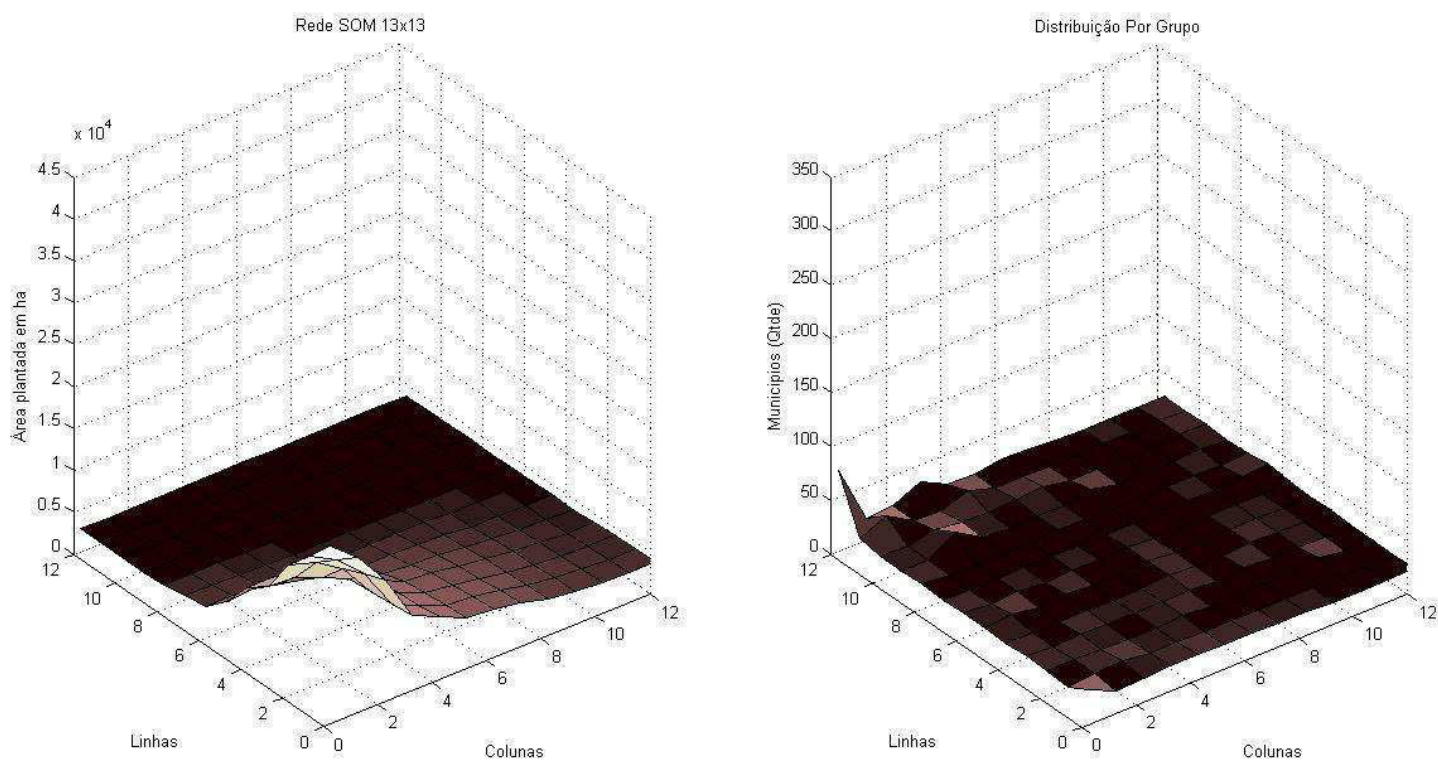
Fonte: Autor (2013).

Figura 36: A esquerda Rede SOFM 9 x 9 (classificação relativa a produtividade); a direita Distribuição por Grupo (Quantitativo de municípios classificados).





Fonte: Autor (2013).

Figura 37: A esquerda Rede SOM 13 x 13 (classificação relativa a produtividade); a direita Distribuição por Grupo (Quantitativo de municípios classificados).



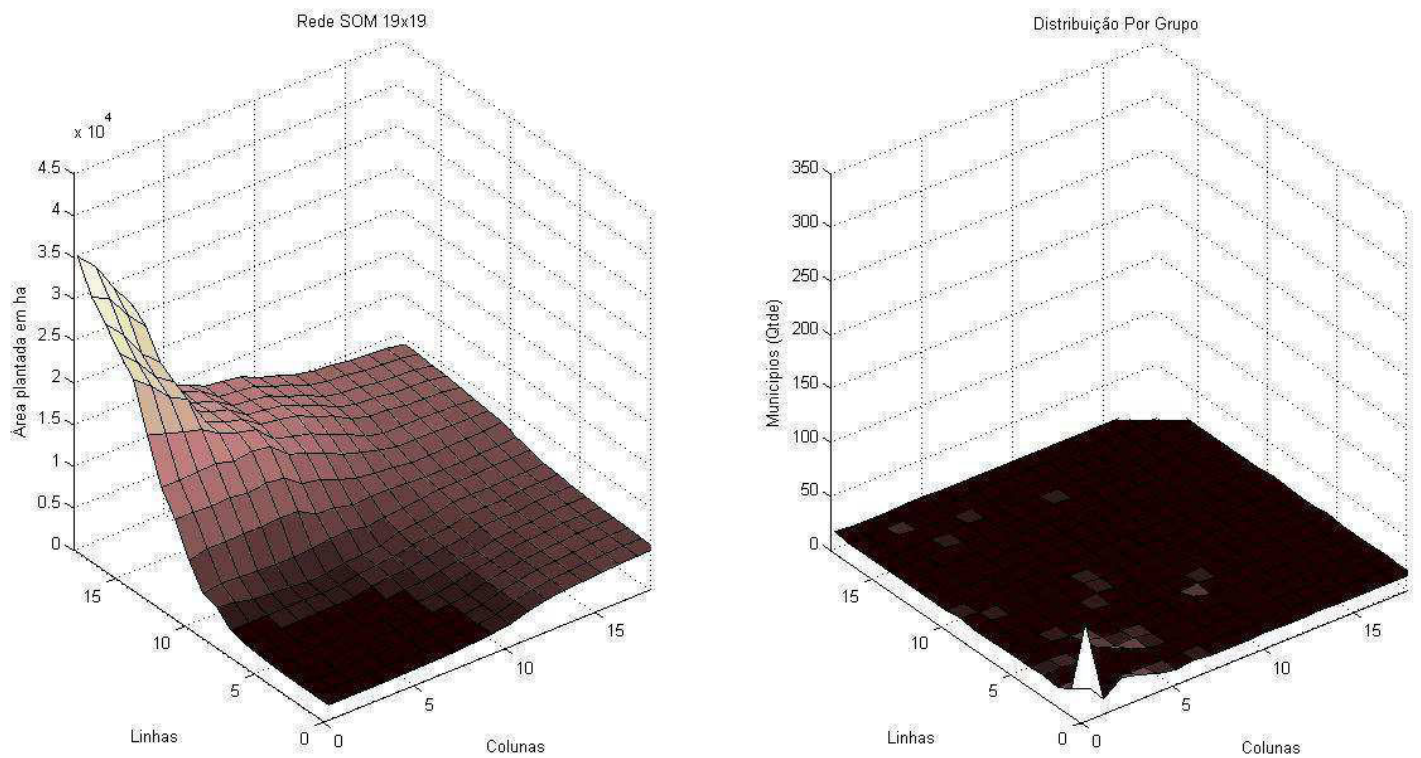
Fonte: Autor (2013).

Figura 38: A esquerda Rede SOM 17 x 17 (classificação relativa a produtividade); a direita Distribuição por Grupo (Quantitativo de municípios classificados).



Fonte: Autor (2013).

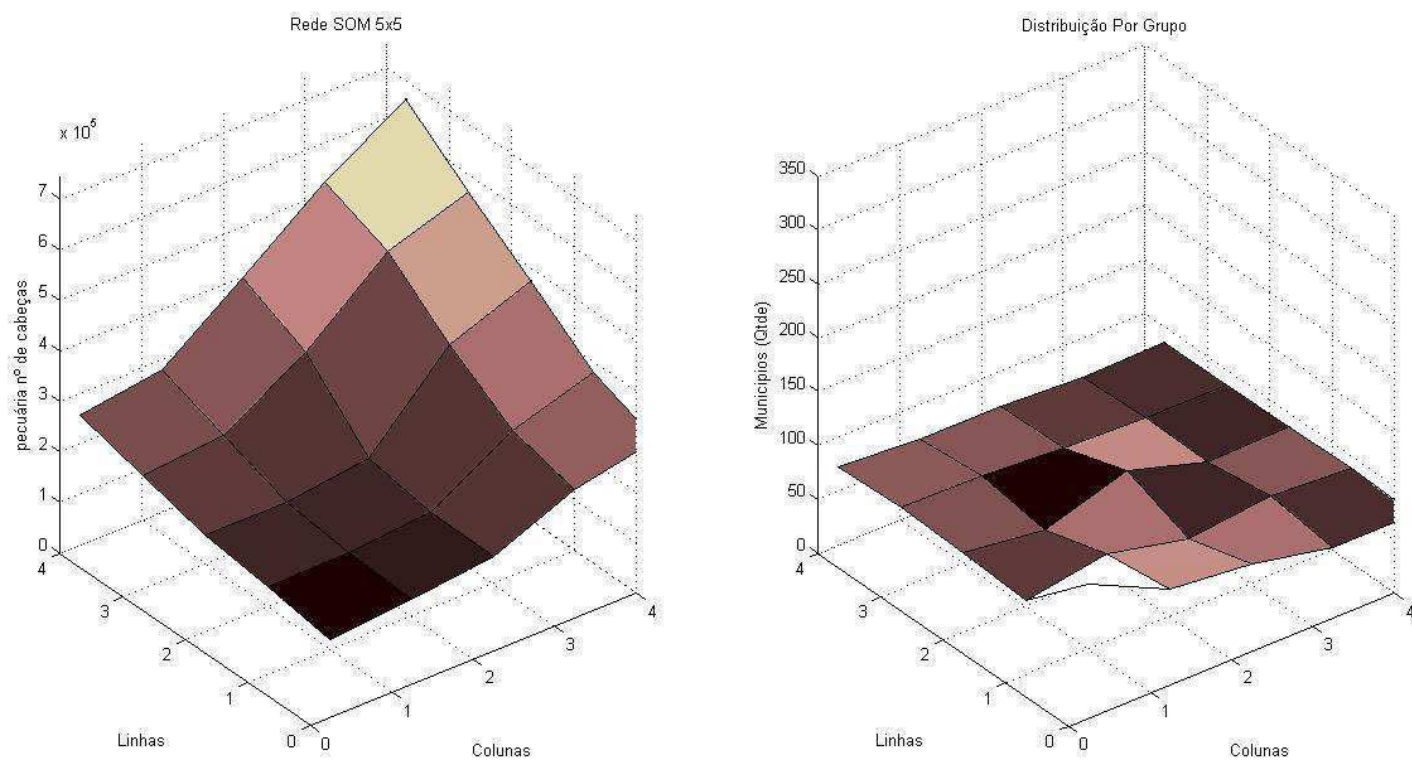
Figura 39: A esquerda Rede SOM 19 x 19 (classificação relativa a produtividade); a direita Distribuição por Grupo (Quantitativo de municípios classificados).



Fonte: Autor (2013).

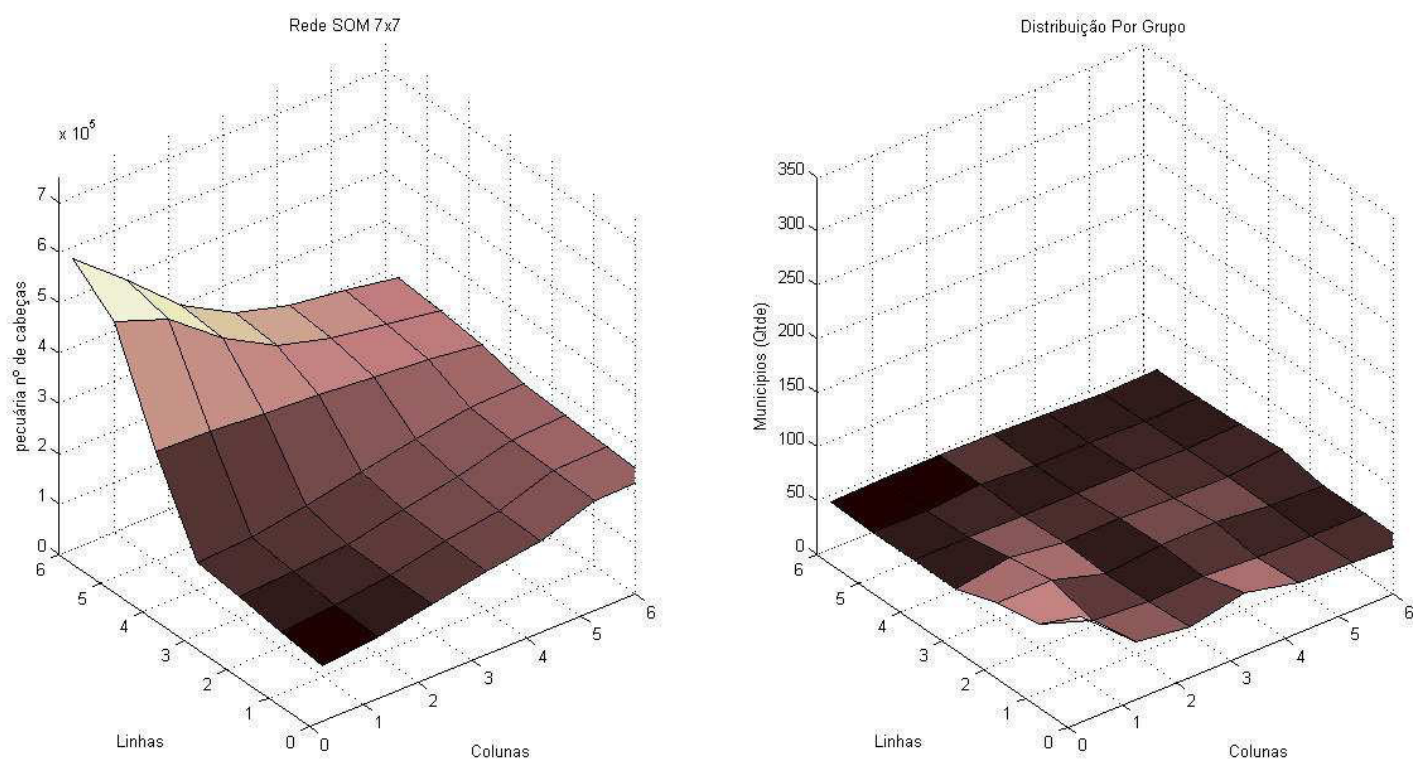
B.2 – Pecuária bovina de corte em número de cabeças

Figura 40: A esquerda Rede SOFM 5 x 5 (classificação relativa a produtividade); a direita Distribuição por Grupo (Quantitativo de municípios classificados).



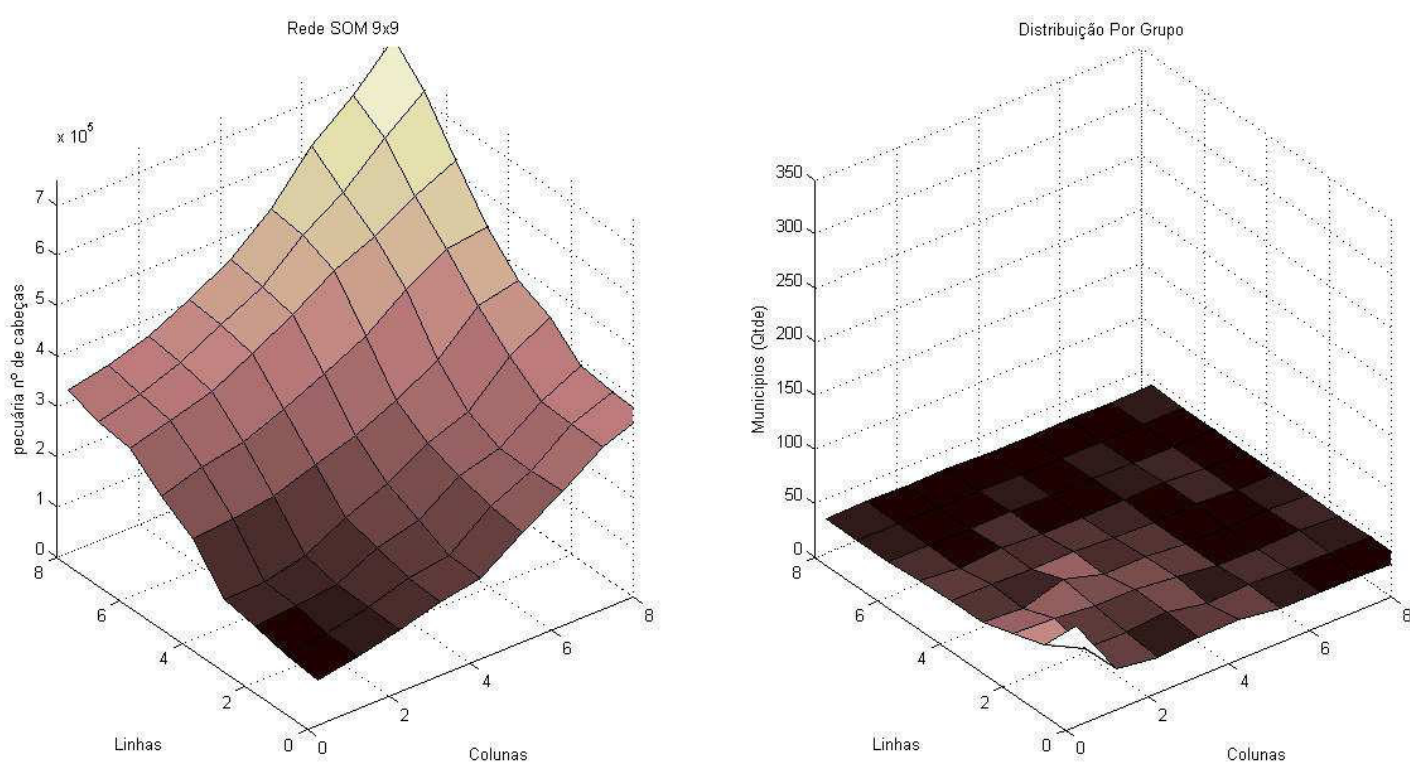
Fonte: Autor (2013).

Figura 41: A esquerda Rede SOM 7 x 7 (classificação relativa a produtividade); a direita Distribuição por Grupo (Quantitativo de municípios classificados).



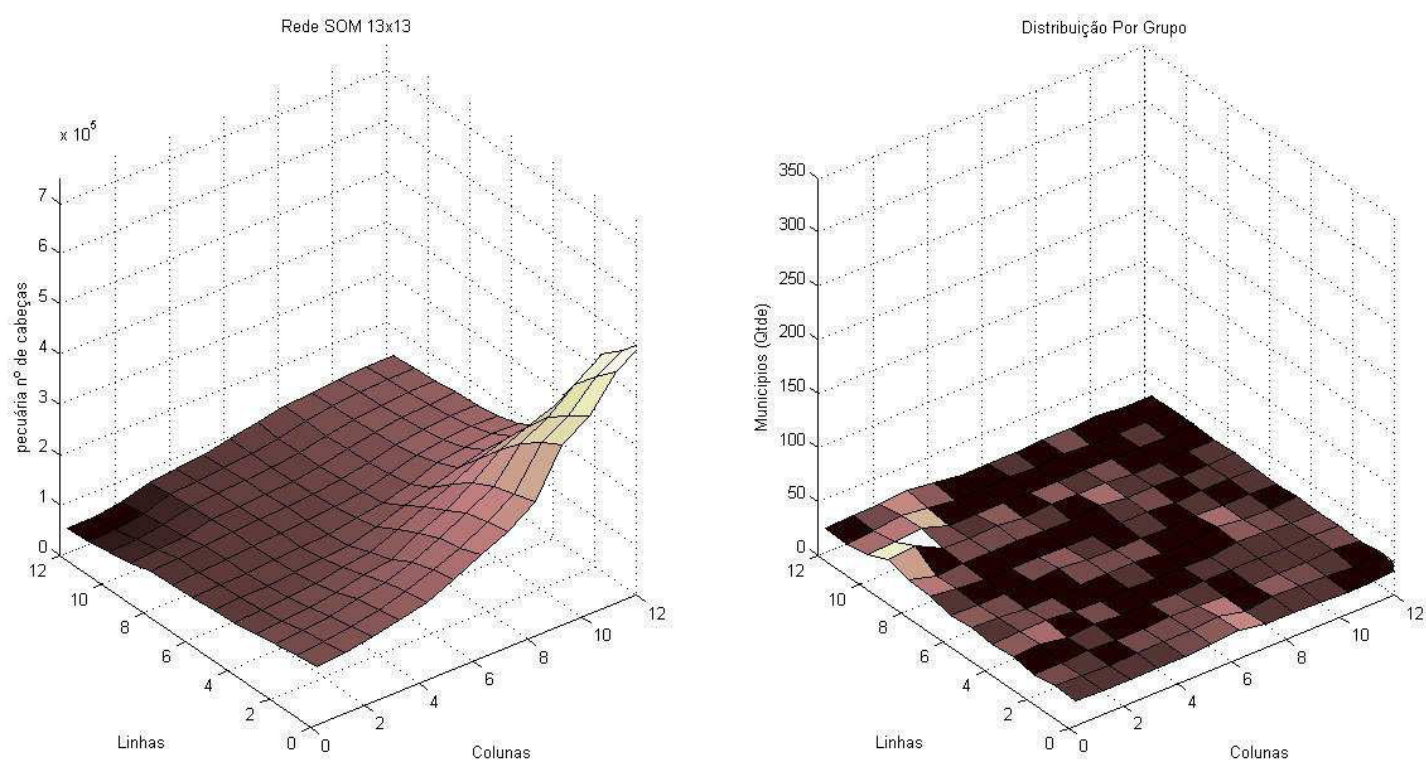
Fonte: Autor (2013).

Figura 42: A esquerda Rede SOFM 9 x 9 (classificação relativa a produtividade); a direita Distribuição por Grupo (Quantitativo de municípios classificados).



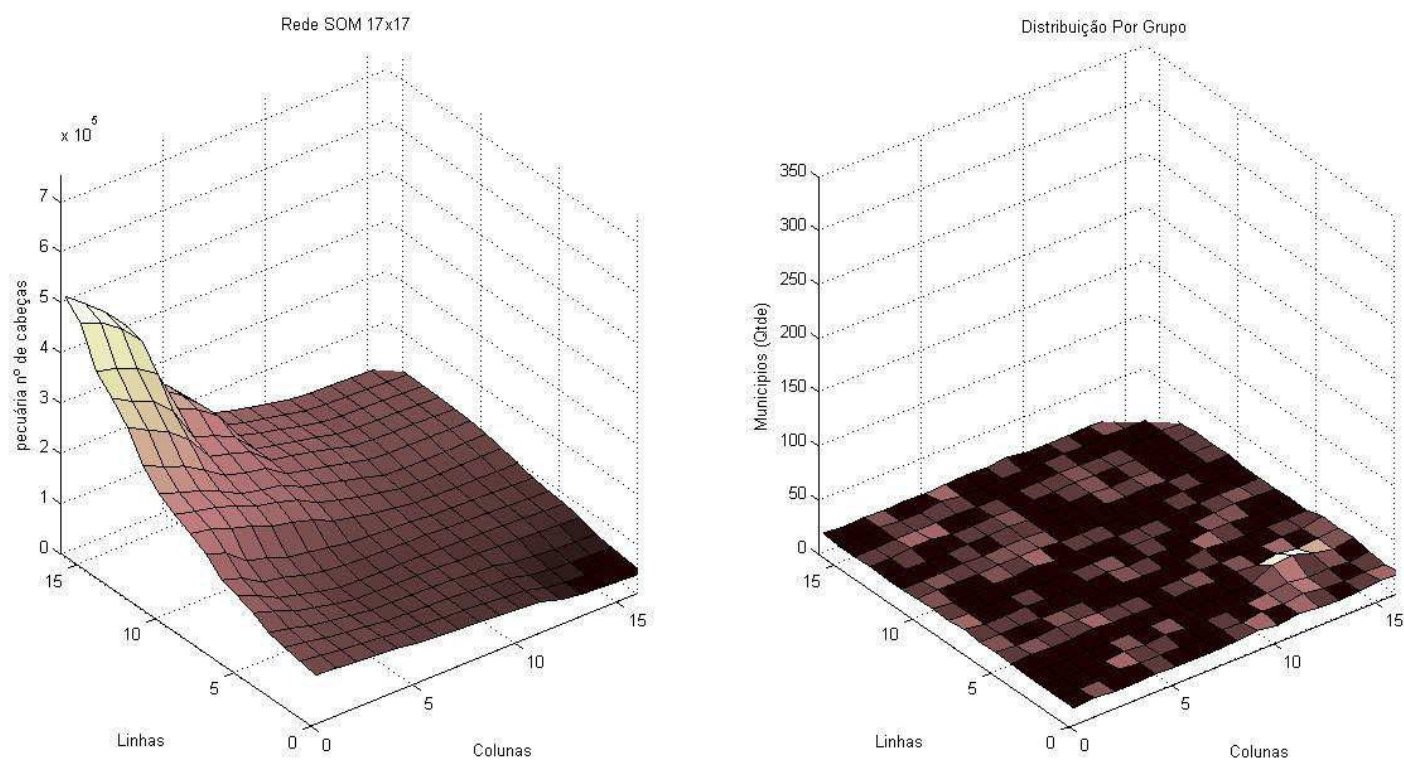
Fonte: Autor (2013).

Figura 43: A esquerda Rede SOM 13 x 13 (classificação relativa a produtividade); a direita Distribuição por Grupo (Quantitativo de municípios classificados).



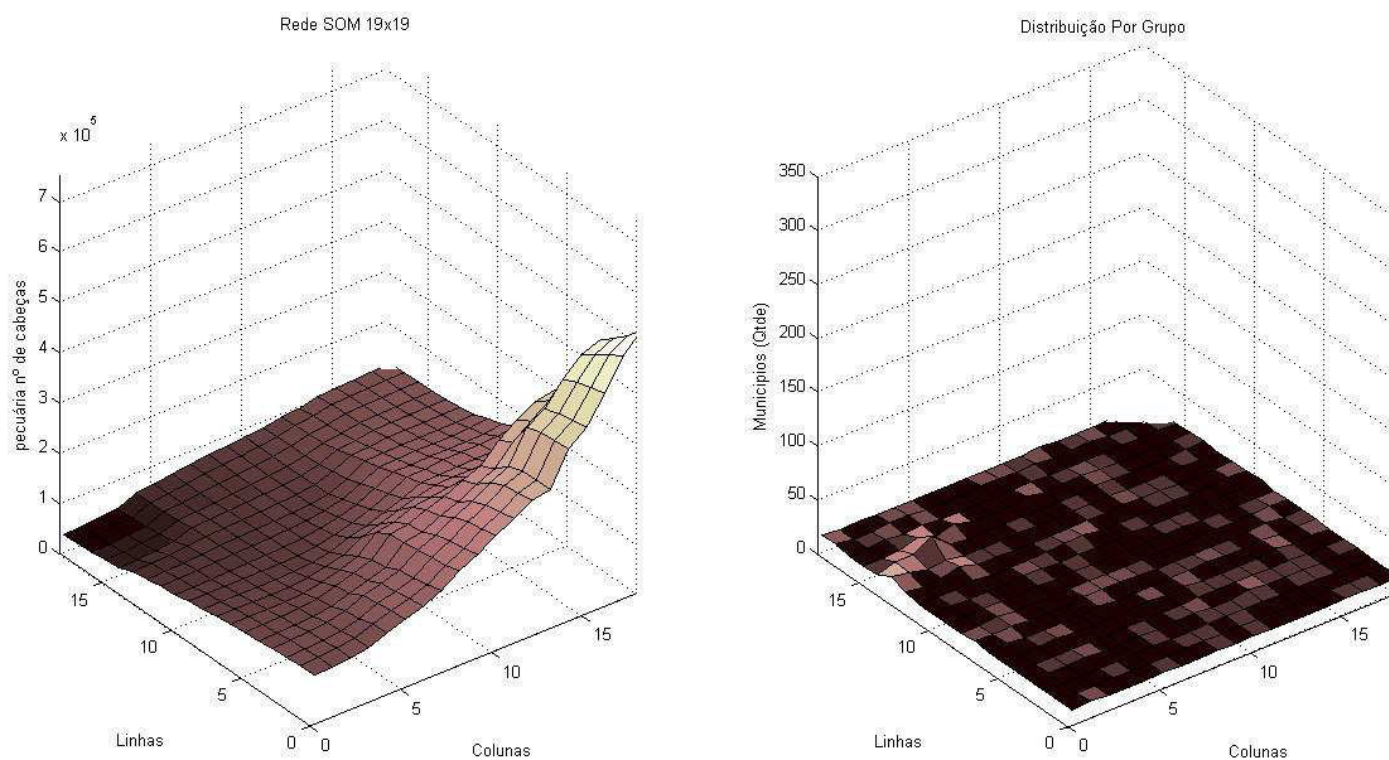
Fonte: Autor (2013).

Figura 44: A esquerda Rede SOFM 17 x 17 (classificação relativa a produtividade); a direita Distribuição por Grupo (Quantitativo de municípios classificados).



Fonte: Autor (2013).

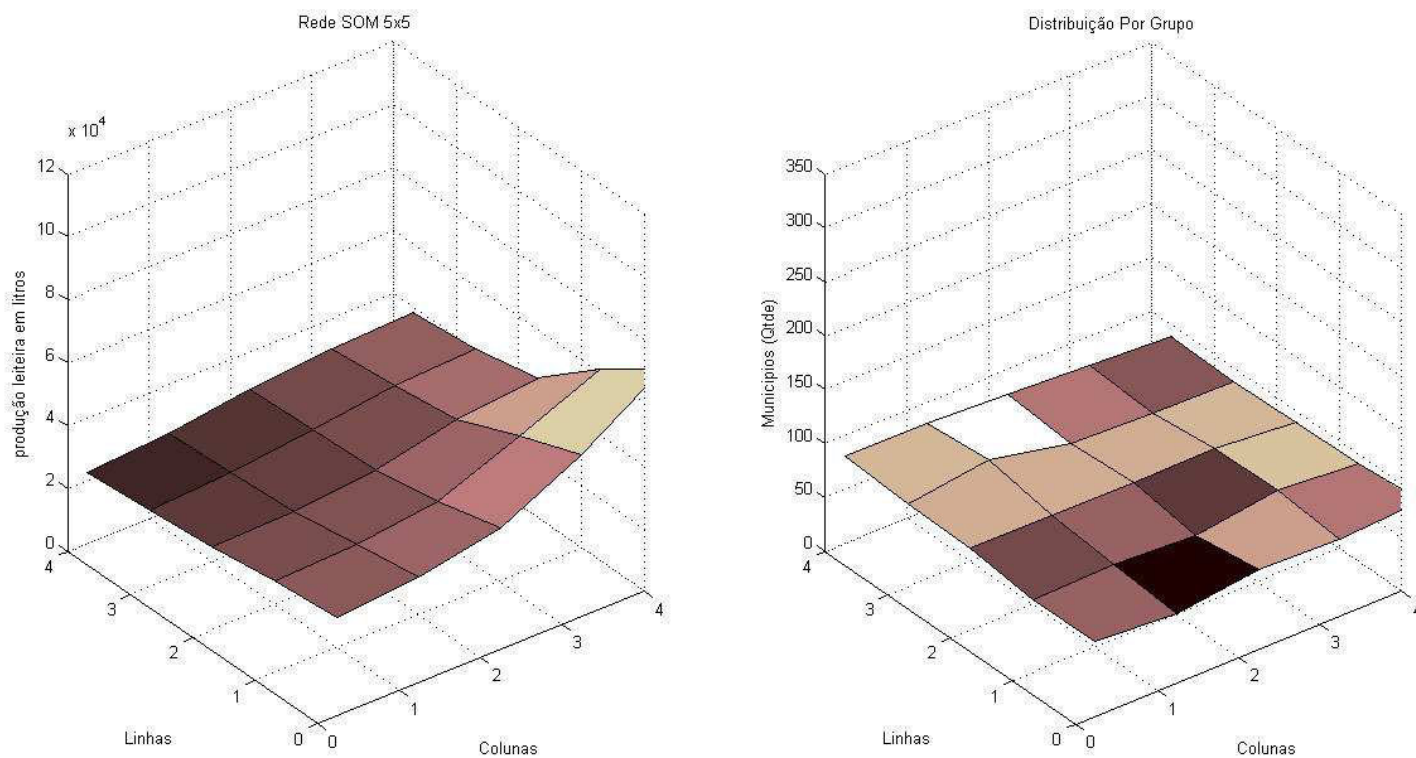
Figura 45: A esquerda Rede SOM 19 x 19 (classificação relativa a produtividade); a direita Distribuição por Grupo (Quantitativo de municípios classificados).



Fonte: Autor (2013).

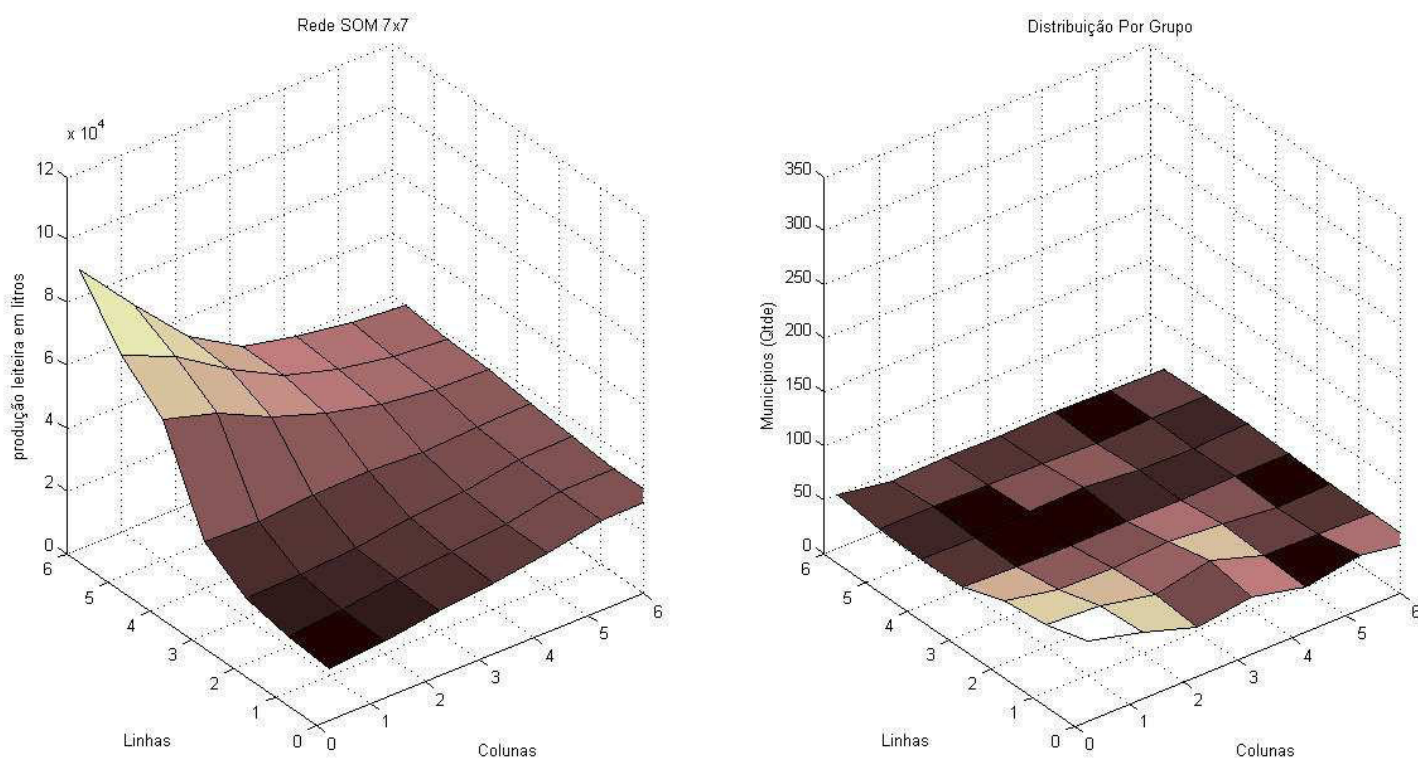
B.3 – Pecuária leiteira em litros

Figura 46: A esquerda Rede SOFM 5 x 5 (classificação relativa a produtividade); a direita Distribuição por Grupo (Quantitativo de municípios classificados).





Fonte: Autor (2013).

Figura 47: A esquerda Rede SOFM 7 x 7 (classificação relativa a produtividade); a direita Distribuição por Grupo (Quantitativo de municípios classificados).



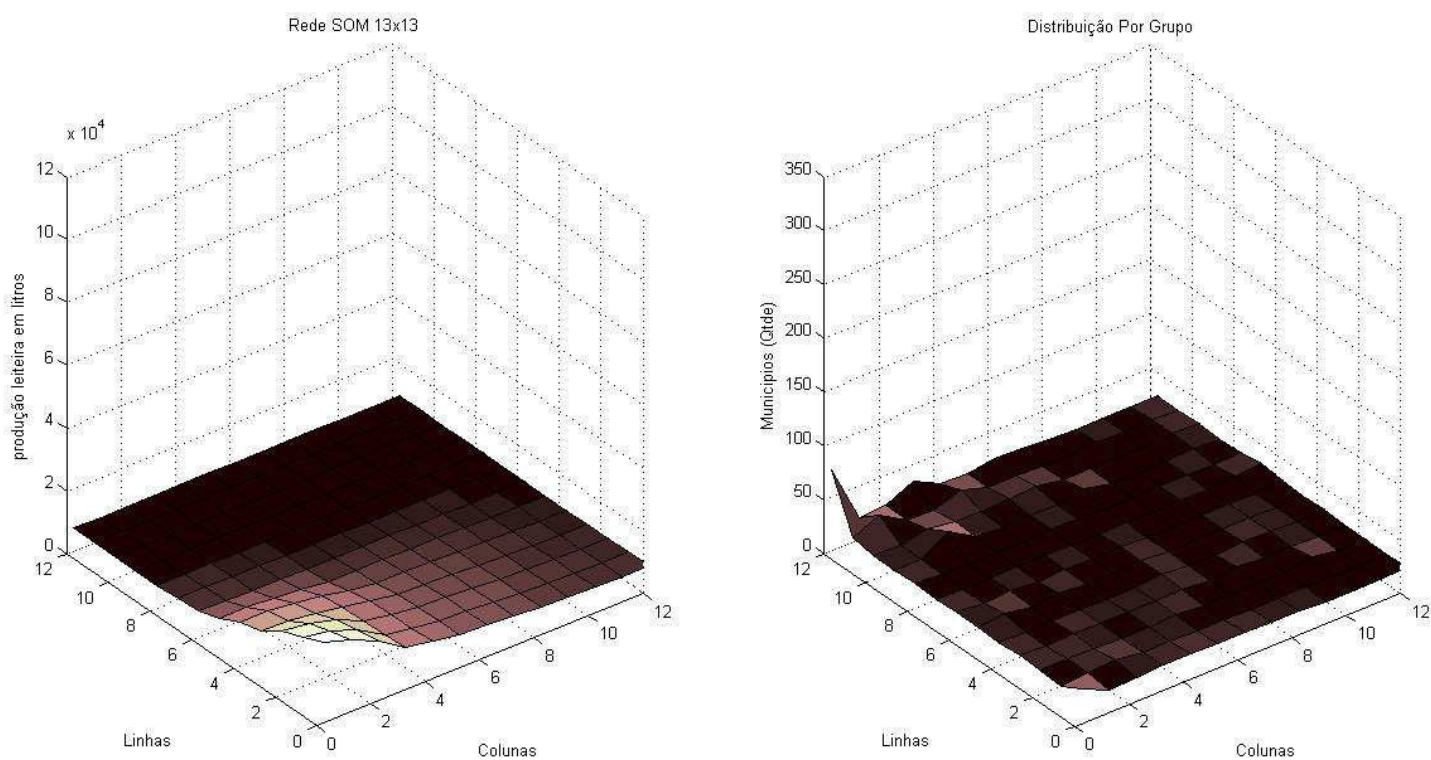
Fonte: Autor (2013).

Figura 48: A esquerda Rede SOM 9 x 9 (classificação relativa a produtividade); a direita Distribuição por Grupo (Quantitativo de municípios classificados).



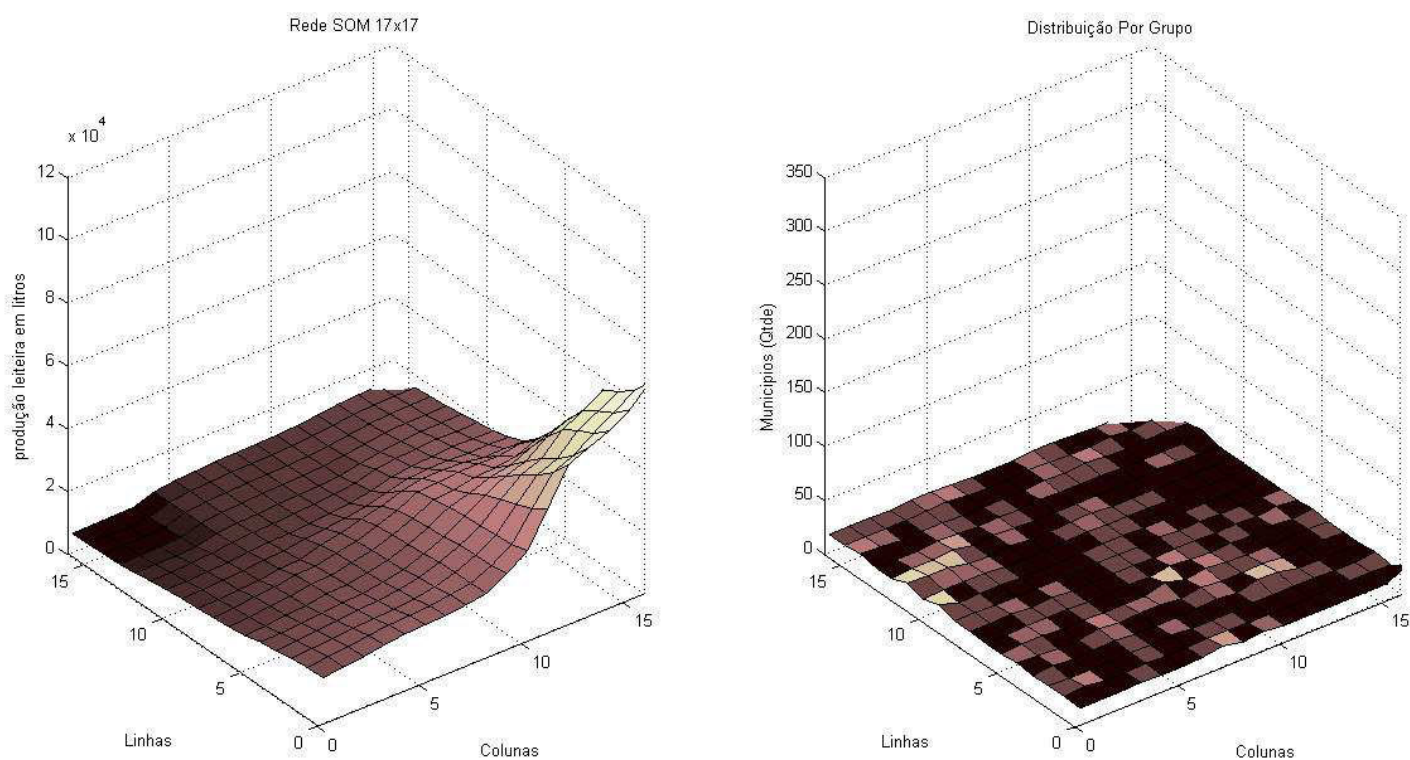
Fonte: Autor (2013).

Figura 49: A esquerda Rede SOM 13 x 13 (classificação relativa a produtividade); a direita Distribuição por Grupo (Quantitativo de municípios classificados).



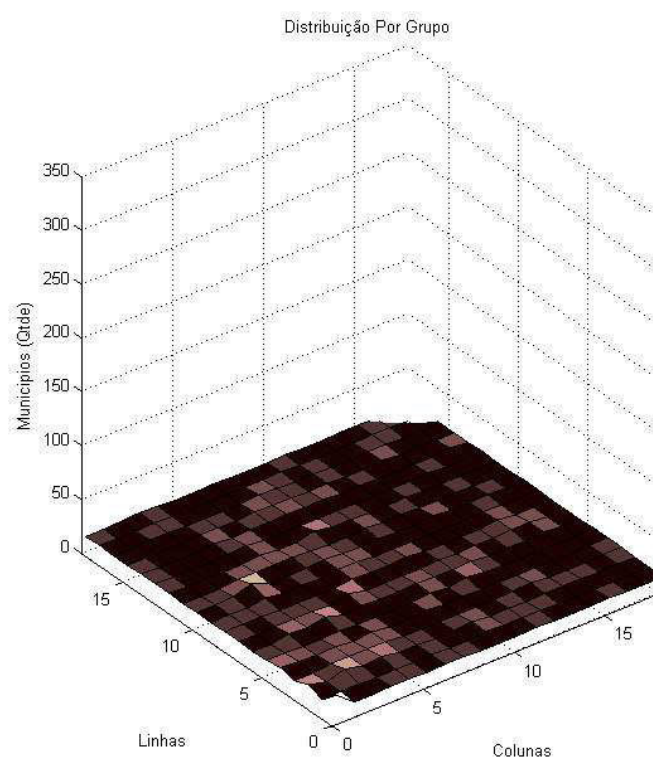

Fonte: Autor (2013).

Figura 50: A esquerda Rede SOM 17 x 17 (classificação relativa a produtividade); a direita Distribuição por Grupo (Quantitativo de municípios classificados).



Fonte: Autor (2013).

Figura 51: A esquerda Rede SOM 19 x 19 (classificação relativa a produtividade); a direita Distribuição por Grupo (Quantitativo de municípios classificados).



Fonte: Autor (2013).