



UNIVERSIDADE  
ESTADUAL DE LONDRINA

---

HÁGATA CREMASCO DA SILVA

**APLICAÇÃO DE REDES NEURAIS ARTIFICIAIS DO TIPO  
MAPAS AUTO-ORGANIZÁVEIS:  
ESTUDO DE CASOS**

---

Londrina  
2014

HÁGATA CREMASCO DA SILVA

**APLICAÇÃO DE REDES NEURAIS ARTIFICIAIS DO TIPO  
MAPAS AUTO-ORGANIZÁVEIS:  
ESTUDO DE CASOS**

Dissertação apresentada ao Programa de Mestrado em Química da Universidade Estadual de Londrina como cumprimento às exigências para obtenção do título de Mestre em Química.

Orientador: Prof. Dr. Dionisio Borsato  
Co-orientador: Prof. Dr. Marcos Valle

Londrina  
2014

**Catálogo elaborado pela Divisão de Processos Técnicos da Biblioteca Central da  
Universidade Estadual de Londrina**

**Dados Internacionais de Catalogação-na-Publicação (CIP)**

S586a	<p>Silva, Hágata Cremasco da. Aplicação de redes neurais artificiais do tipo mapas auto-organizáveis : estudo de casos / Hágata Cremasco da Silva. – Londrina, 2014. 76 f. : il.</p> <p>Orientador: Dionísio Borsato. Coorientador: Marcos Eduardo Ribeiro do Valle Mesquita. Dissertação (Mestrado em Química) – Universidade Estadual de Londrina, Centro de Ciências Exatas, Programa de Pós-Graduação em Química, 2014. Inclui bibliografia.</p> <p>1. Química inorgânica – Teses. 2. Soja – Compostos inorgânicos – Teses. 3. Redes neurais (Computação) – Teses. 4. Mapas auto- organizáveis – Teses. 5. Reconhecimento de padrões – Teses. 6. Café – Compostos inorgânicos – Teses. I. Borsato, Dionísio. II. Mesquita, Marcos Eduardo Ribeiro do Vale. III. Universidade Estadual de Londrina. Centro de Ciências Exatas. Programa de Pós-Graduação em Química. IV. Título.</p> <p style="text-align: right;">CDU 546</p>
-------	---

HÁGATA CREMASCO DA SILVA

**APLICAÇÃO DE REDES NEURAIS ARTIFICIAIS DO TIPO MAPAS  
AUTO-ORGANIZÁVEIS: ESTUDO DE CASOS**

Dissertação apresentada ao Programa de Mestrado em Química da Universidade Estadual de Londrina como cumprimento às exigências para obtenção do título de Mestre em Química.

**BANCA EXAMINADORA**

---

Orientador: Prof. Dr. Dionisio Borsato  
UEL – Londrina – PR

---

Profa. Dra. Ieda Spacino Scarmínio  
UEL – Londrina – PR

---

Prof. Dr. Evandro Bona  
UTFPR – Campo Mourão – PR

Londrina, 18 de fevereiro de 2014.

## **AGRADECIMENTOS**

A minha mãe, Meire, por sempre estar ao meu lado me apoiando, me dando forças nos momentos difíceis;

A minha irmã, Pâmela por seu companheirismo durante estes 2 anos;

A meu noivo, Patrick ao longo de 10 anos vem me apoiando, meu porto seguro, pessoa com que contei em todos os momentos, sempre esteve ao meu lado me incentivando e compartilhando comigo os melhores e piores momentos de todos estes anos;

Aos amigos que fiz durante o curso, que com certeza foram muito importantes na minha vida em todos estes anos e continuarão sendo mesmo depois desta jornada (Jaqueline, Matheus, Paula, Flávia e Karina). Em especial a minha amiga Juliane, pessoa em que encontrei outra irmã, uma amiga que faz tudo parecer mais simples na vida, pessoa que me ensinou muitas coisas e que admiro muito por sua bondade e simplicidade. Que foi minha dupla em todo esse período aquela em podia contar em todos os momentos, parceira pra vida toda;

Ao Prof. Dr. Evandro Bona e ao Prof. Dr Marcos Valle, pela colaboração com este trabalho;

Ao meu orientador e pai, Prof. Dr. Dionisio Borsato, pelo apoio, ensinamentos de vida, compreensão, dedicação, carinho, confiança, por seu exemplo de pessoa, professor, pesquisador e mais que tudo por sua amizade;

A todos os professores do programa de Mestrado em Química, pois sem eles nada disto seria possível, agradeço a cada um em especial, pela contribuição para minha formação acadêmica;

A todos os funcionários da Universidade que possibilitam que tudo isso aconteça.

CREMASCO, Hágata. **Aplicação de redes neurais artificiais do tipo mapas auto-organizáveis: estudo de casos**. 2014. 76 f. Dissertação (Mestrado em Química) – Universidade Estadual de Londrina, Londrina, 2014.

## RESUMO

Foram analisadas quarenta amostras de soja, transgênicas e comuns, plantadas em duas regiões diferentes, Londrina e Ponta Grossa. A fim de verificar se os valores de concentração dos compostos inorgânicos na soja eram diferentes em função da região de plantio, as concentrações de K, P, Ca, Mg, S, Zn, Mn, Fe, Cu e B foram analisados por uma Rede Neural Artificial do tipo Mapa Auto Organizável (MAO). Foi observado que a rede foi capaz de diferenciar as amostras conforme sua região de origem. Entretanto, não foi observada a diferenciação das amostras quanto a transgenia. Também foram analisadas cento e setenta e duas amostras de café oriundas de 16 cidades diferentes, do estado do Paraná, que foram divididas em três regiões de acordo com o clima e temperatura das cidades. As concentrações de K, P, Ca, Mg, S, Zn, Mn, Fe, Cu e B foram analisadas por uma Rede Neural Artificial do tipo Mapa Auto Organizável e foi constatado que não foi possível a separação das amostras em relação à região de origem. Em relação às cidades, algumas puderam ser agrupadas e outras não. Em uma segunda análise verificou-se um bom agrupamento das cidades, formando um total de 6 grupos distintos. Também foi possível constatar que das 10 variáveis utilizadas 3 delas, K, Mg e Mn, não exerciam muita influência nos resultados apresentados. Neste último estudo foi constatado que as 3 variáveis retiradas da análise eram importantes da construção das relações das vizinhanças dos grupos. Apesar dos grupos formados terem sido os mesmos, as relações de vizinhança não permaneceram iguais. Foi possível constatar, portanto, que as concentrações de P, Ca, K, Mg, Mn, S, Zn, Fe, Cu e B aplicados à rede do tipo MAO foram capazes de reconhecer 10 cidades, formando 6 grupos distintos. De acordo com os resultados obtidos a RNA do tipo MAO se mostrou uma ferramenta importante e adequada no reconhecimento de padrões nos dois casos estudados.

**Palavras-chave:** Inteligência artificial. Redes de Kohonen. Aprendizagem competitiva. Soja. Café.

CREMASCO, Hágata. **Aplicação de redes neurais artificiais do tipo mapas auto-organizáveis: estudo de casos.** 2014. 76 p. Dissertação (Mestrado em Química) – Universidade Estadual de Londrina, Londrina, 2014.

### **ABSTRACT**

Forty samples of soybean, transgenic and common, planted in two different regions, Londrina and Ponta Grossa were analyzed. In order to verify whether the values of the concentration of the inorganic compounds in soybeans were different according to the region of planting, the concentrations of K, P, Ca, Mg, S, Zn, Mn, Fe, Cu and B were analyzed by Artificial Neural Network Self Organizing Map type (SOM). It was observed that the network was able to differentiate the samples according to their region of origin. However, no differentiation of samples for genetic modification was observed. One hundred seventy-two coffee samples coming from 16 different cities in the state of Paraná, which were divided into three regions according to the climate and temperature of cities were also analyzed. The concentrations of K, P, Ca, Mg, S, Zn, Mn, Fe, Cu and B were analyzed by an Artificial Neural Network Self Organizing Map type. It was noted that it was not possible to separate the samples in relation to the region of origin. Regarding hometowns, some might be grouped and others not. In this second analysis showed a good grouping of cities, for a total of 6 groups. It also appeared that the 10 variables used 3 of them, K, Mg and Mn did not exercise much influence on the results presented. In the latter study it was found that 3 variables from the analysis were important for construction of relations of neighborhood groups. Despite the trained groups were the same, neighborly relations did not remain equal. It was established, so that the concentrations of P, Ca, K, Mg, Mn, S, Zn, Fe, Cu and B applied to the type SOM network were able to recognize 10 cities, forming 6 groups. According to the results of the ANN type SOM showed a significant and appropriate tool in recognizing patterns in the two cases studied.

**Key words:** Artificial intelligence. Kohonen networks. Competitive learning. Soy. Coffee.

## LISTA DE ILUSTRAÇÕES

<b>Figura 1</b> – Neurônio biológico .....	16
<b>Figura 2</b> – Neurônio artificial não linear.....	18
<b>Figura 3</b> – Mapa auto-organizável segundo o modelo de Kohonen (MARINI, <i>et al.</i> , 2007 .....	19
<b>Figura 4</b> – Erro de treinamento em função das épocas, dados soja .....	29
<b>Figura 5</b> – Distribuição das amostras de acordo com o neurônio vencedor, dados soja .....	29
<b>Figura 6</b> – Mapa de pesos da variável Fe (mg.kg <sup>-1</sup> ), dados soja .....	30
<b>Figura 7</b> – Mapa de pesos da variável Mn (mg.kg <sup>-1</sup> ), dados soja.....	31
<b>Figura 8</b> – Mapa de pesos da variável S (g kg <sup>-1</sup> ), dados soja .....	31
<b>Figura 9</b> – Mapa de pesos da variável Cu (mg kg <sup>-1</sup> ), dados soja .....	32
<b>Figura 10</b> – Mapa de pesos da variável B (mg kg <sup>-1</sup> ), dados soja .....	32
<b>Figura 11</b> – Mapa de pesos da variável P (g kg <sup>-1</sup> ), dados soja .....	33
<b>Figura 12</b> – Mapa de pesos da variável Mg (g kg <sup>-1</sup> ), dados soja.....	34
<b>Figura 13</b> – Mapa de pesos da variável K (g kg <sup>-1</sup> ), dados soja .....	34
<b>Figura 14</b> – Mapa de pesos da variável Ca (g kg <sup>-1</sup> ), dados soja .....	35
<b>Figura 15</b> – Mapa de pesos da variável Zn (mg.kg <sup>-1</sup> ), dados soja .....	36
<b>Figura 16</b> – Erro de treinamento em função das épocas, (dados café, 172 amostras e 10 variáveis).....	39
<b>Figura 17</b> – Distribuição das amostras de acordo com o neurônio vencedor, (dados café, 172 amostras e 10 variáveis) .....	40
<b>Figura 18</b> – Distribuição das amostras de acordo com o neurônio vencedor: a) para região A e b) para as cidades que compõem esta região, (dados café, 49 amostras e 10 variáveis) .....	41
<b>Figura 19</b> – Distribuição das cidades da região A sobre o mapa de pesos das variáveis: a) Ca (g kg <sup>-1</sup> ), b) Cu (mg kg <sup>-1</sup> ), c) Fe (mg kg <sup>-1</sup> ), d) K (g kg <sup>-1</sup> ), e) Mg (g kg <sup>-1</sup> ), f) Mn (mg kg <sup>-1</sup> ), g) P (g kg <sup>-1</sup> ), h) S (g kg <sup>-1</sup> ), i) Zn (mg kg <sup>-1</sup> ) e j) B (mg kg <sup>-1</sup> ), (dados café, 49 amostras e 10 variáveis).....	42
<b>Figura 20</b> – Distribuição das amostras de acordo com o neurônio vencedor: a) para região B e b) para as cidades que compõem esta região, (dados café, 69 amostras e 10 variáveis) .....	44

<b>Figura 21</b> – Distribuição das cidades da região B sobre o mapa de pesos das variáveis: a) Ca ( $\text{g kg}^{-1}$ ), b) Cu ( $\text{mg kg}^{-1}$ ), c) Fe ( $\text{mg kg}^{-1}$ ), d) K ( $\text{g kg}^{-1}$ ), e) Mg ( $\text{g kg}^{-1}$ ), f) Mn ( $\text{mg kg}^{-1}$ ), g) P ( $\text{g kg}^{-1}$ ), h) S ( $\text{g kg}^{-1}$ ), i) Zn ( $\text{mg kg}^{-1}$ ) e j) B ( $\text{mg kg}^{-1}$ ), (dados café, 69 amostras e 10 variáveis).....	45
<b>Figura 22</b> – Distribuição das amostras de acordo com o neurônio vencedor: a) para região C e b) para as cidades que compõem esta região, (dados café, 61 amostras e 10 variáveis) .....	47
<b>Figura 23</b> – Distribuição das cidades da região C sobre o mapa de pesos das variáveis: a) Ca ( $\text{g kg}^{-1}$ ), b) Cu ( $\text{mg kg}^{-1}$ ), c) Fe ( $\text{mg kg}^{-1}$ ), d) K ( $\text{g kg}^{-1}$ ), e) Mg ( $\text{g kg}^{-1}$ ), f) Mn ( $\text{mg kg}^{-1}$ ), g) P ( $\text{g kg}^{-1}$ ), h) S ( $\text{g kg}^{-1}$ ), i) Zn ( $\text{mg kg}^{-1}$ ) e j) B ( $\text{mg kg}^{-1}$ ), (dados café, 61 amostras e 10 variáveis).....	48
<b>Figura 24</b> – Distribuição das amostras de acordo com o neurônio vencedor para as cidades <b>a, d, e, g, h, j, k, l, o e p</b> .....	50
<b>Figura 25</b> – Erro de treinamento em função das épocas, (dados café, 96 amostras 10 variáveis).....	52
<b>Figura 26</b> – Distribuição das amostras de acordo com o neurônio vencedor: a) em relação às regiões e b) em relação às cidades, (dados café, 96 amostras 10 variáveis) .....	53
<b>Figura 27</b> – Distribuição das cidades selecionadas sobre o mapa de pesos das variáveis: a) Ca ( $\text{g kg}^{-1}$ ), b) Cu ( $\text{mg kg}^{-1}$ ), c) Fe ( $\text{mg kg}^{-1}$ ), d) K ( $\text{g kg}^{-1}$ ), e) Mg ( $\text{g kg}^{-1}$ ), f) Mn ( $\text{mg kg}^{-1}$ ), g) P ( $\text{g kg}^{-1}$ ), h) S ( $\text{g kg}^{-1}$ ), i) Zn ( $\text{mg kg}^{-1}$ ) e j) B ( $\text{mg kg}^{-1}$ ), (dados café, 96 amostras 10 variáveis).....	55
<b>Figura 28</b> – Gráfico do erro de treinamento em função das épocas, (dados café, 96 amostras 7 variáveis) .....	57
<b>Figura 29</b> – Distribuição das amostras de acordo com o neurônio vencedor: a) treinamento com 96 amostras e 10 variáveis e b) treinamento com 96 amostras e 7 variáveis .....	58
<b>Figura 30</b> – Distribuição das cidades selecionadas sobre o mapa de pesos das variáveis: a) Ca ( $\text{g kg}^{-1}$ ), b) Cu ( $\text{mg kg}^{-1}$ ), c) Fe ( $\text{mg kg}^{-1}$ ), d) P ( $\text{g kg}^{-1}$ ), e) S ( $\text{g kg}^{-1}$ ), f) Zn ( $\text{mg kg}^{-1}$ ) e g) B ( $\text{mg kg}^{-1}$ ), (dados café, 96 amostras 7 variáveis).....	58

## LISTA DE TABELAS

<b>Tabela 1</b> – Valor de máximo, mínimo, média, desvio padrão e teste de Tukey para os dados de soja em relação a cidades de origem.....	26
<b>Tabela 2</b> – Valor de máximo, mínimo, média, desvio padrão e teste de Tukey para os dados de soja em relação a cidades de origem e ao tipo de soja comum ou transgênica .....	27
<b>Tabela 3</b> – Divisão da amostragem das cidades em regiões, 172 amostras.....	37
<b>Tabela 4</b> – Valor de máximo, mínimo, média e desvio padrão para os dados de café em relação às regiões de origem.....	38
<b>Tabela 5</b> – Divisão da amostragem das cidades em regiões, 96 amostras.....	50
<b>Tabela 6</b> – Valor de máximo, mínimo, média e desvio padrão para os dados de café em relação às regiões de origem, sem levar em consideração as cidades, <b>b, c, f, i, m e n</b> .....	51

## LISTA DE ABREVIATURAS E SIGLAS

ACP	Análise de Componentes Principais
AOAC	Association of Official Analytical Chemists
EMPBRAPA	Empresa Brasileira de Pesquisa Agropecuária
IAPAR	Instituto Agronômico do Paraná
L	Londrina
LC	Londrina Comum
LT	Londrina Trangênica
MAO	Mapa Auto-Organizável
PG	Ponta Grossa
PGC	Ponta Grossa Comum
PGT	Ponta Grossa Trangênica
RNA	Redes Neurais Artificiais
SOM	Self Organizing Maps

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO</b> .....	12
<b>2</b>	<b>OBJETIVOS</b> .....	15
2.1	GERAL .....	15
2.2	ESPECÍFICOS .....	15
<b>3</b>	<b>REDES NEURAIS ARTIFICIAIS</b> .....	16
3.1	NEURÔNIO BIOLÓGICO.....	16
3.2	NEURÔNIO ARTIFICIAL .....	17
3.3	RNA DO TIPO MAO .....	18
3.4	ARQUITETURA E ALGORITMO DA RNA DO TIPO MAO .....	19
<b>4</b>	<b>MATERIAIS E MÉTODOS</b> .....	23
4.1	SOJA.....	23
4.1.1	Amostras .....	23
4.1.2	Minerais .....	23
4.2	CAFÉ .....	23
4.2.1	Amostras .....	24
4.2.2	Minerais .....	24
4.3	REDES NEURAIS ARTIFICIAIS.....	24
4.4	PROCESSAMENTO COMPUTACIONAL PARA AMOSTRAS DE SOJA E CAFÉ.....	24
<b>5</b>	<b>RESULTADOS E DISCUSSÃO</b> .....	25
5.1	SOJA.....	25
5.2	CAFÉ .....	37
	<b>CONCLUSÃO</b> .....	60
	<b>REFERÊNCIAS</b> .....	61

<b>ANEXOS</b> .....	64
<b>ANEXO A</b> – Tabela de concentração dos componentes inorgânicos das amostras de soja utilizadas .....	65
<b>ANEXO B</b> – Tabela de concentração dos componentes inorgânicos das amostras de café utilizadas .....	67
<b>ANEXO C</b> – Tabela de valores de máximo, mínimo, média e desvio padrão para os dados de café em relação às regiões de origem, sem levar em consideração as cidades, <b>b, c, f, i, m e n</b> .....	74

## 1 INTRODUÇÃO

Ao longo dos anos a ciência vem evoluindo de maneira extraordinária. A grande quantidade de equipamentos de alta eficiência para diferentes finalidades faz com que a quantidade de informação produzida atualmente seja tão grande, que a extração de informações dos resultados de um experimento torna-se muito difícil sem o auxílio de alguma ferramenta de processamento de dados. Muitas vezes, um pequeno número das variáveis envolvidas na análise dos dados contém as informações mais relevantes, enquanto que a maioria das variáveis possui pouca ou nenhuma influência na interpretação dos resultados (NETO e MOITA, 1998).

Uma dessas ferramentas já muito conhecida é a Análise de Componentes Principais (ACP), onde as  $n$ -variáveis originais geram, através de suas combinações lineares na qual,  $n$ -componentes principais, cuja principal característica, além da ortogonalidade, que são apresentados em ordem decrescente de máxima variância, ou seja, a componente principal 1 detém mais informação estatística que a componente principal 2, que por sua vez tem mais informação estatística que a componente principal 3 e assim por diante (NETO e MOITA, 1998).

Uma ferramenta que tem se mostrado adequada nos tratamentos onde os dados possuem comportamentos não lineares, são as Redes Neurais Artificiais (RNAs). A origem da teoria de Redes Neurais remonta aos modelos matemáticos e aos modelos da engenharia de neurônios biológicos (KOVÁCS, 1996). As RNAs procuram modelar, mesmo que primitivamente, as operações lógicas pelas quais o cérebro executa as mais variadas tarefas (DEISINGH *et al.*, 2004, LIAO, 2005).

A utilização das RNA permite obter não somente ganhos significativos de desempenho, mas também possibilita o desenvolvimento de aplicações inovadoras capazes de expandir de forma extraordinária nossos sentidos e habilidades intelectuais e, com isso, permite avaliar a influência de cada atributo auxiliando os especialistas em suas tomadas de decisões (CORNEY, 2002).

Nas últimas décadas essa ferramenta vem ganhando espaço no reconhecimento e classificação de padrões (WARNER e MISRA, 1996; BONA, *et al.*, 2012). O fato das RNA serem aptas a resolver problemas de cunho geral, tais como

aproximação, classificação, categorização e predição (BRAGA. *et al.*, 2000), fez com que este conjunto de técnicas fosse aplicado numa vasta gama de áreas, com destaque para controle de processos, navegação por satélites, previsão do tempo, processamento de sinais, reconhecimento de fala, tratamento de resíduos, engenharia de cerâmicas, detecção de incêndios, mercado financeiro, auxílio ao diagnóstico de doenças, entre outros (MUKESH, 1996; AZEVEDO, *et al.*, 2000; HUNTER *et al.*, 2000; HAMMOND *et al.*, 2004; LIAO, 2005).

As redes neurais são muitas vezes referidas como ferramentas heurísticas do tipo “caixa preta” (BOGER, 2003; KOLMAN e MARGALOT, 2005), entretanto alguns trabalhos recentes (BONA, 2012; SPACINO, *et al.*, 2013) têm apresentado maneiras para extrair conhecimento a partir do modelo do mapeamento entrada-saída construído por uma rede neural.

Existem vários tipos de redes neurais tais como perceptron de uma ou múltiplas camadas, redes de base radial, mapas auto-organizáveis, dentre outros. O MAO ou SOM, do inglês Self Organizing Maps, também conhecidas como redes neurais de Kohonen, pois fora desenvolvido pelo professor Teuvo Kohonen, tem como objetivo transformar um padrão de entrada incidente, de dimensão arbitrária, em um mapa discreto uni- ou bidimensional e realizar esta transformação adaptativamente de uma maneira topologicamente ordenada. O resultado pode ser observado através de um mapa topológico que tem como função facilitar a visualização de agrupamentos e também a relação de vizinhança entre os grupos formados. Grupos próximos partilham alguma similaridade, ou seja, quanto maior a distância euclidiana maior será a diferença de comportamento (KOHONEN, 1997).

Foram encontradas varias aplicações para os MAO: Determinação de comportamento de colonização de plantas aquáticas (PITELLI, *et al.*, 2009), previsão de elementos químicos da tabela periódica (LEMES, *et al.*, 2008), na área de alimentos (VERDINI *et al.* 2007;BOISHEBERT *et al.*, 2006); em análises químicas (TOKUTAKA, *et al.*, 1999) e classificação de petróleo conforme o pais de origem (FONSECA *et al.*, 2006).

Em relação a todos os tipos de grãos produzidos no mundo, a soja foi a que mais cresceu em termos percentuais. De 1970 a 2007 o crescimento da produção global foi da ordem de 763%, enquanto que as produções de culturas como trigo, arroz, milho, feijão, cevada e girassol cresceram, no máximo, uma terceira parte desse montante. O Brasil é o segundo maior produtor de soja do

mundo e representa 40% da produção total de grãos. Os estados brasileiros produtores de soja são: RS, SC, PR, GO, MG, MS, MT, BA, MA e PI (DALL'AGNOL, *et al.*, 2007).

Dentre todos os componentes da soja os mais importantes, tanto no aspecto nutricional quanto comercial, são a proteína e o óleo (FERRARI, *et al.*, 2005). Mas a soja também pode ser uma excelente fonte de minerais como K, P, Ca, Mg, S, Zn, Mn, Fe, Cu e B, que em geral são muito utilizados no metabolismo em processos enzimáticos (LEE, 1966).

Outro grão de grande interesse para o comércio mundial é o café perdendo em valor somente para o petróleo (NOGUEIRA, 2005). Além disso, é a matéria prima de uma das bebidas mais aceitas no mundo (MAEZTU *et al.*, 2001). Uma característica interessante da bebida do café é o fato de não possuir valor nutricional relevante, sendo consumida basicamente devido aos efeitos fisiológicos e psicológicos relacionados à presença da cafeína e, principalmente, pelo prazer e satisfação que seu aroma e sabor são capazes de proporcionar (GROSCH, 2001).

Existem várias tentativas para se associar à composição do café verde com a qualidade da bebida (MAZZAFERA, 1999). O clima confere certos atributos especiais da bebida, o corpo, a acidez e o aroma ao café de cada região. O Paraná apresenta uma diversidade de clima e solo que permite a produção dos mais diversos tipos de café (ANDROCIOLI *et al.*, 2003). Entretanto, a ocorrência de pragas e doenças de forma mais ou menos intensa, das condições climáticas, do estado das plantas e de eventuais desequilíbrios durante o período de cultivo podem provocar a perda de qualidade resultando em cafés com bebidas de baixos padrões de qualidade (MATIELLO *et al.*, 1994).

## 2 OBJETIVOS

### 2.1 GERAL

Este trabalho tem como proposta aplicar e adaptar a metodologia de RNA, do tipo MAO, para identificar padrões de comportamento a partir da concentração dos componentes inorgânicos de amostras de soja e café.

### 2.2 ESPECÍFICOS

- Identificação de amostras de soja quanto sua classificação por cidade de origem com base na concentração dos componentes inorgânicos.
- Identificação de amostras de café quanto sua classificação por região e cidade de plantio com base na concentração dos componentes inorgânicos.

### 3 REDES NEURAIS ARTIFICIAIS


Para definir e compreender uma RNA deve-se analisar três aspectos:

- (i) *Neurônio*: Unidade básica da rede;
- (ii) *Arquitetura*: Maneira como os neurônios estão conectados entre si;
- (iii) *Algoritmo de aprendizagem*: responsável por adaptar a rede para uma determinada função.

#### 3.1 NEURÔNIO BIOLÓGICO

O neurônio é a unidade celular fundamental do cérebro que é o centro do sistema nervoso humano (MUKESH, 1996; HAYKIN, 2001). Como se pode observar na Figura 1, cada neurônio é formado por um corpo celular, responsável pelo metabolismo celular, de onde se projetam extensões filamentosas, os dendritos e o axônio. O neurônio possui geralmente um único axônio, embora este possa apresentar algumas ramificações e estender-se por vários metros (KOVÁCS, 1996).

**Figura 1** – Neurônio biológico



A conexão entre o axônio de um neurônio e os dendritos de outros neurônios é chamada de sinapse. E pode ser resumida como uma conexão simples que impõe ao neurônio receptivo excitação ou inibição, mas não ambas (HAYKIN, 2001). Os sinais que chegam por estes axônios são pulsos elétricos conhecidos como impulsos nervosos e constituem a informação que o neurônio processará de alguma forma para produzir como saída um impulso nervoso no seu axônio (KOVÁCS, 1996). Os eventos em um circuito de silício acontecem na ordem de

nanossegundos ( $10^{-9}$  s), enquanto que os eventos neurais acontecem na ordem de milissegundos ( $10^{-3}$  s). Entretanto, o cérebro compensa a taxa de operação relativamente baixa de um neurônio pelo número realmente espantoso de neurônios, com conexões maciças entre si. O resultado é que o cérebro é uma estrutura extremamente eficiente (HAYKIN, 2001).

A capacidade de adaptação e armazenamento de conhecimento em um cérebro adulto pode ser atribuída a dois mecanismos: a criação de novas conexões sinápticas entre os neurônios e a modificação das sinapses existentes. Assim, define-se o conhecimento: informação armazenada ou modelos utilizados por uma pessoa ou máquina para interpretar; prever e responder apropriadamente ao mundo exterior (HAYKIN, 2001).

Uma RNA se assemelha ao cérebro em dois aspectos: (i) O conhecimento é adquirido pela rede a partir de seu ambiente através de um processo de aprendizagem. (ii) Forças de conexão entre neurônios, conhecidas como pesos sinápticos, são utilizadas para armazenar o conhecimento adquirido (HAYKIN, 2001).

### 3.2 NEURÔNIO ARTIFICIAL


O primeiro modelo de neurônio artificial proposto por McCulloch e Pitts em 1943 é uma simplificação de um neurônio biológico. Eles interpretaram o funcionamento do neurônio biológico como sendo um circuito de entradas binárias combinadas por uma soma ponderada (com pesos) produzindo uma entrada efetiva (DIN, 2013).

De maneira geral um neurônio artificial, Figura 2, é constituído por 3 elementos básicos:

- (i) *Sinapses*: composta pelos sinais de entrada ( $x_n$ ), neurônio ( $k$ ) e pelos pesos sinápticos ( $w_{kn}$ );
- (ii) *Junção aditiva*: soma os sinais de entrada levando em consideração seus respectivos pesos e gerando uma saída ( $u_k$ );
- (iii) *Função de Ativação*: que restringe o valor do sinal de saída para um valor finito, que resulta no sinal de saída do neurônio ( $y_k$ ) (HAYKIN, 2001).

Além disso, um termo importante presente em um neurônio é o bias  $b_k$  que tem como função de aumentar ou diminuir a influência do valor de entrada.

**Figura 2** – Neurônio artificial não linear



Pode-se representar matematicamente um neurônio da seguinte forma:

$$y_k = f(u_k) = f\left(\sum_{j=0}^m w_{kj}x_j\right) \quad (1)$$

Cada neurônio artificial pode receber vários estímulos de entrada e gerar vários estímulos de saída. Sendo que, este fluxo de estímulos é propagado através de uma rede de conexões, tal qual no modelo biológico. A intensidade de propagação dos estímulos entre uma determinada conexão é feita através de pesos de ponderação. Os sinais ponderados recebidos são somados e modificados através de uma função de transferência.

O sucesso do método está relacionado com a topologia da rede e os parâmetros adotados no algoritmo de treinamento. Dependendo da escolha, a aprendizagem pode ficar presa em um mínimo local ou convergir lentamente (LINDER e PÖPPL, 2003).

### 3.3 RNA DO TIPO MAO

Neste trabalho foi utilizado o MAO de Kohonen o qual faz parte de um grupo de RNA chamados redes baseadas em modelos de competição, onde os neurônios de saída da grade competem entre si para serem disparados ou ativados,


com o resultado que apenas um neurônio está ligado em um instante de tempo. Esse neurônio é chamado de neurônio vencedor. Estas redes combinam competição com uma forma de aprendizagem para fazer os ajustes de seus pesos. Outra característica importante deste tipo de rede é que elas utilizam treinamento não supervisionado, onde a rede busca encontrar similaridades baseando-se apenas nos padrões de entrada. O principal objetivo dos mapas auto-organizáveis de Kohonen é agrupar os dados de entrada que são semelhantes entre si formando classes ou agrupamentos denominados *clusters* (KOHONEN, 1997).

### 3.4 ARQUITETURA E ALGORITMO DA RNA DO TIPO MAO

A Figura 3 representa o arranjo dos neurônios utilizado na rede do tipo MAO na qual, os neurônios estão distribuídos em linhas e colunas, sendo que cada neurônio tem conexões com todos os elementos do vetor de entrada.

Cada neurônio apresenta a mesma quantidade de pesos, que é igual ao número de variáveis analisadas. Na Figura 3,  $k$  representa o número de padrões de entrada,  $m$  é a quantidade de variáveis de entrada e  $N$  é o número de neurônios em cada dimensão (MARINI, *et al.*, 2007).

**Figura 3** – Mapa auto-organizável segundo o modelo de Kohonen (MARINI, *et al.*, 2007)



O primeiro processo que ocorre é a inicialização, onde são atribuídos pesos aos dados de entrada de forma aleatória, para não formatar o mapa com uma tendência inicial de se organizar. Após a inicialização, ocorrem três processos, competição, cooperação e adaptação sináptica.

No processo competitivo, a rede utiliza a regra “o vencedor leva tudo” para reajustar os pesos e assim ensinar a rede um novo conceito. Este processo ocorre através da medida da distância euclidiana de cada neurônio em relação a cada padrão de entrada. O neurônio que apresentar a menor distância é chamado de neurônio vencedor, aquele que melhor atende ao estímulo proporcionado pelo vetor de entrada.

O neurônio vencedor localiza o centro de uma função que representa a vizinhança topológica de neurônios cooperativos. No cérebro humano existem regiões especializadas para cada tipo de estímulo e resposta desejada como fala, locomoção, memória e assim por diante. Na rede neural não é diferente. Para que sejam criadas regiões especializadas em cada padrão de entrada é que existe o processo cooperativo.

A função escolhida para representar a vizinhança topológica foi a função gaussiana, equação 2, pois ela possui as duas propriedades necessária para satisfazer o objetivo proposto. Ela é simétrica em relação ao ponto de máximo definido pela posição do neurônio vencedor e sua amplitude é monotonamente decrescente com o aumento da distância em relação ao neurônio vencedor. Isto porque, quanto mais distante um neurônio vizinho estiver do neurônio vencedor menos ele participará de sua vizinhança e também menor será o reajuste sofrido (BONA, *et al.*, 2012).

$$h_{j,t} = \exp\left(-\frac{d_{i,j}^2}{2\sigma^2}\right) \quad (2)$$

Na equação  $2\sigma$  é o raio efetivo da vizinhança topológica, que mede o grau de participação dos neurônios vizinhos ao vencedor no processo de aprendizagem,  $d_{i,j}$  é a distância lateral entre o neurônio vencedor  $i$  e o neurônio excitado  $j$ , que também é definida através da distância euclidiana (BONA, 2008).

O tempo é um aspecto relevante para o ajuste de vizinhança, pois com o passar do tempo, regiões cada vez menores se especializam em certo padrão

de entrada. Por isso, no início, a função de vizinhança deve ser suficientemente larga para cobrir todo o mapa. Porém à medida que o treinamento prossegue a largura deve ser diminuída, criando assim as regiões especializadas a um determinado padrão de entrada. Uma maneira de implementar a redução é através de um decaimento exponencial do tipo representado pela equação 3 (BONA, 2008).

$$\sigma(n) = \sigma_0 \exp\left(-\frac{n}{\tau_1}\right) \quad n = 0, 1, 2, \dots \quad (3)$$

Onde  $\sigma_0$  é o raio efetivo na inicialização do algoritmo e  $\tau_1$  é a constante de tempo inicial recomendada, sendo  $\tau_1 = \log(1000/\sigma_0)$ , e  $n$  o número de épocas de treinamento, ou seja, a quantidade de vezes que a rede processou os dados de entrada (BONA, 2008).

No processo adaptativo ocorre o reajuste dos pesos sinápticos fazendo a rede aprender um novo conceito. É relevante entender como o conhecimento se conserva ao longo do tempo. No sistema biológico com o passar dos anos fica cada vez mais difícil aprender algo, isto não é uma falha, mas sim um mecanismo de proteção, pois se um ser humano de 60 anos aprendesse com a mesma eficiência do que um com 3 anos de idade nosso conhecimento seria transitório e com o passar do tempo se esqueceria da maior parte das coisas aprendidas no passado, assim para garantir a durabilidade da nossa memória nosso fator de aprendizagem decai com o tempo (BONA, 2008).

A equação 4 define como acontece o processo adaptativo da rede, onde

$$w_j(n+1) = w_j(n) + \eta(n) h_j f_{\omega}(x - w_j(n)) \quad (4)$$

$\eta(n)$  é a taxa de aprendizagem que, como representado, deve ser variável e decrescente ao longo das  $n$  épocas de treinamento.

O processo adaptativo é subdividido em duas etapas, ordenação e convergência. Na etapa de ordenação a taxa de aprendizagem é maior para garantir que a rede sofra maiores modificações uma vez que o mapa se encontra totalmente

desordenado. Na etapa de convergência a taxa de aprendizagem é menor e existe uma adaptação mais refinada dos pesos.

O decréscimo da taxa de aprendizagem é realizado através de um decaimento exponencial, como apresentado na equação 5.

$$\eta(n) = \eta_0 \exp\left(-\frac{n}{\tau_2}\right) \quad n = 0, 1, 2 \dots \quad (5)$$

Nesta equação,  $\eta_0$  é a taxa de aprendizagem inicial e  $\tau_2$  é outra constante de tempo, sendo os valores recomendados, respectivamente, 0,1 e 1000 (HAYKIN, 2001).

## 4 MATERIAIS E MÉTODOS

### 4.1 SOJA

O banco de dados utilizado foi disponibilizado pelo Prof. Dr. Olívio Fernandes Galão - Universidade Estadual de Londrina.

#### 4.1.1 Amostras

Foram estudadas 20 variedades de soja desenvolvidas pela Embrapa de Londrina e recomendadas para plantio na região Centro-Sul do Brasil para safra 2008/2009, sendo 6 cultivares transgênicas e 14 convencionais. Essas 20 variedades foram plantadas simultaneamente em Londrina e Ponta Grossa, totalizando 40 amostras. As duas cidades apresentam clima, terreno e temperatura média diferentes e os solos receberam igual tratamento de adubação e calagem.

#### 4.1.2 Minerais

As cinzas foram determinadas em triplicata, de acordo com a metodologia T47.01 (AOAC, 1990) e a análise de minerais contidos foi realizada segundo a metodologia recomendada pela AOAC (1990), que consiste na digestão das amostras com ácido clorídrico 6,0 mol L<sup>-1</sup>. A determinação da concentração dos minerais foi realizada com espectrômetro de emissão atômica com plasma de argônio induzido (ICP-AES) da Perkin-Elmer Optima 3300 DV. Os padrões de trabalho foram preparados por diluição dos padrões de estoque.

### 4.2 CAFÉ

Os dados utilizados foram fornecidos pelo Instituto Agrônomo do Paraná (IAPAR), localizada em Londrina Paraná.

#### 4.2.1 Amostras

Foram coletadas amostras de 16 cidades distribuídas no Estado do Paraná, abrangendo lavouras de café da região de solo argiloso e arenito totalizando 172 amostras. De cada local foram colhidos cerca de 3 kg de café, transportadas para Londrina-PR no mesmo dia em que foi colhido. No IAPAR, as amostras foram colocadas imediatamente em caixas de madeira com fundo de tela e movimentada oito vezes ao dia até os grãos atingirem 11-12% de umidade. As amostras foram congeladas em nitrogênio líquido e moídas em moinho de disco com uma granulometria final de 0,6 mm. A seguir foram mantidas congeladas em freezer e descongeladas à medida que foram analisadas.

#### 4.2.2 Minerais

As concentrações de P, Ca, Mg, Cu, Zn, B, Mn, Fe e S em amostras de café foram determinadas em espectrômetro de emissão óptica por Plasma Acoplado Indutivamente (ICP-OES) da marca Thermo Jarrel após digestão nitroperclórica. O potássio foi determinado por fotometria de chama em fotômetro Micronal. Os padrões dos minerais foram preparados por diluições de estoque (PAVAN, 1992).

#### 4.3 REDES NEURAS ARTIFICIAIS

Foi utilizada uma rotina desenvolvida no software MATLAB R2007b conforme o algoritmo descrito em Haykin (2001) e os valores da concentração de cálcio, magnésio, fósforo, potássio e enxofre em  $\text{g kg}^{-1}$  de amostra, manganês, zinco, cobre, ferro e boro em  $\text{mg kg}^{-1}$  de amostra, tanto para soja quanto para o café, foram tabulados e apresentados a rede neural.

#### 4.4 PROCESSAMENTO COMPUTACIONAL PARA AMOSTRAS DE SOJA E CAFÉ

Todos os resultados dos experimentos foram processados em um computador Intel® Core™ i3-370M, 2,0 Gb de memória RAM e 500GB HDD.

## 5 RESULTADOS E DISCUSSÃO

### 5.1 SOJA

No anexo A, encontra-se a tabela com os dados das concentrações dos componentes inorgânicos utilizados para alimentar a rede neural e também para o estudo estatístico dos dados, como valores máximos e mínimos, média, desvio padrão e teste de Tukey em nível de 5% e, apresentados nas Tabelas 1 e 2. As médias destacadas em vermelho foram aquelas em que o teste de Levene's, que analisa a homogeneidade da variância, se mostrou significativo em nível de 5%. Portanto, para estes parâmetros a aplicação do teste de Tukey não é recomendada (CALADO e MONTGOMERY, 2003).

Na Tabela 1, foram comparados os resultados para as duas cidades de origem sem levar em consideração o tipo de soja. Apenas para as concentrações de K, P, Mg, Fe, Cu e B foi possível utilizar o teste de Tukey que mostrou diferença significativa entre as médias das duas cidades apenas para as concentrações de K, P, Mg e Cu.

Na Tabela 2, o teste de Tukey, foi realizado comparando as amostras em relação a origem e o tipo comum e transgênica. Neste caso podemos observar que o teste pôde ser aplicado apenas as concentrações de K, P, Mg e B. Em relação ao K não existe diferença entre as amostras LC e LT e entre LC e PGC, mas existe entre as demais. Para o P existe diferença apenas entre as amostras L e PG. Desta forma, não existe diferença entre amostras comuns e transgênicas. Para o Mg a única média que apresenta diferença é a LT que é diferente das PGC e PGT. Para o B não existe diferença entre as médias.

**Tabela 1** – Valor de máximo, mínimo, média, desvio padrão e teste de Tukey para os dados de soja em relação a cidades de origem

Amostras	Parâmetro	K (g kg <sup>-1</sup> )	P (g kg <sup>-1</sup> )	Ca (g kg <sup>-1</sup> )	Mg (g kg <sup>-1</sup> )	S (g kg <sup>-1</sup> )	Zn (mg kg <sup>-1</sup> )	Mn (mg kg <sup>-1</sup> )	Fe (mg kg <sup>-1</sup> )	Cu (mg kg <sup>-1</sup> )	B (mg kg <sup>-1</sup> )
L	Média	19,7040 <sup>a</sup>	5,0540 <sup>a</sup>	2,6085 <sup>a</sup>	2,3420 <sup>a</sup>	2,3465 <sup>a</sup>	43,1980 <sup>a</sup>	36,1680 <sup>a</sup>	87,3835 <sup>a</sup>	13,3415 <sup>a</sup>	42,4490 <sup>a</sup>
	Desvio Padrão	0,9719	0,4126	0,5139	0,1091	0,1090	5,2806	9,1608	23,4568	1,1980	4,5025
	Mínimo	18,3300	4,5800	1,7400	2,1100	2,1700	36,3900	27,0800	66,7500	11,3000	36,3500
	Máximo	22,1600	6,0000	3,6200	2,5700	2,6400	54,0100	62,4700	148,9400	16,2300	50,0900
PG	Média	18,1715 <sup>b</sup>	4,4465 <sup>b</sup>	1,5545 <sup>b</sup>	2,2395 <sup>b</sup>	2,3210 <sup>a</sup>	29,3665 <sup>b</sup>	19,4145 <sup>b</sup>	97,0905 <sup>a</sup>	11,7690 <sup>b</sup>	41,9150 <sup>a</sup>
	Desvio Padrão	1,0687	0,2723	0,2575	0,1250	0,0319	2,2294	1,7091	18,0346	0,7304	4,0768
	Mínimo	16,4500	3,8900	1,1300	1,9500	2,2600	26,0400	16,6100	76,6000	10,7600	35,2200
	Máximo	20,2500	4,8700	2,0500	2,4700	2,3800	33,2600	22,9100	160,4100	13,0200	49,4100

Amostras em vermelho não pode ser aplicado o teste de Tukey, pois o teste de Levene's se mostrou significativo em nível de 5%. Para o teste de Tukey letras iguais não existe diferença, letras diferentes existe diferença significativa.

**Tabela 2** – Valor de máximo, mínimo, média, desvio padrão e teste de Tukey para os dados de soja em relação a cidades de origem e ao tipo de soja comum ou transgênica

Amostras	Parâmetro	K (g kg <sup>-1</sup> )	P (g kg <sup>-1</sup> )	Ca (g kg <sup>-1</sup> )	Mg (g kg <sup>-1</sup> )	S (g kg <sup>-1</sup> )	Zn (mg kg <sup>-1</sup> )	Mn (mg kg <sup>-1</sup> )	Fe (mg kg <sup>-1</sup> )	Cu (mg kg <sup>-1</sup> )	B (mg kg <sup>-1</sup> )
LC	Média	19,8150 <sup>b</sup>	5,0586 <sup>a</sup>	2,6064 <sup>a</sup>	2,3086 <sup>a,b</sup>	2,3636 <sup>a</sup>	44,4671 <sup>a</sup>	38,6579 <sup>a</sup>	92,7743 <sup>a</sup>	13,4207 <sup>a</sup>	43,1914 <sup>a</sup>
	Desvio Padrão	1,1265	0,4341	0,6063	0,0930	0,1142	5,6458	9,8887	26,3746	1,3910	4,9081
	Mínimo	18,3300	4,5800	1,7400	2,1100	2,2500	36,3900	29,2800	66,7500	11,3000	36,3500
	Máximo	22,1600	6,0000	3,6200	2,5200	2,6400	54,0100	62,4700	148,9400	16,2300	50,0900
LT	Média	19,4450 <sup>b,c</sup>	5,0433 <sup>a</sup>	2,6133 <sup>a</sup>	2,4200 <sup>a</sup>	2,3067 <sup>a</sup>	40,2367 <sup>a</sup>	30,3583 <sup>b</sup>	74,8050 <sup>a</sup>	13,1567 <sup>a,b</sup>	40,7167 <sup>a</sup>
	Desvio Padrão	0,4188	0,3959	0,2189	0,1110	0,0924	2,8374	2,6057	3,3166	0,6041	3,0428
	Mínimo	18,9200	4,6400	2,4000	2,2800	2,1700	36,5300	27,0800	70,8100	12,3800	37,4200
	Máximo	20,0400	5,6300	3,0200	2,5700	2,4100	44,3200	33,7300	79,4300	14,0800	44,9100
PGC	Média	18,5671 <sup>c</sup>	4,5386 <sup>b</sup>	1,6150 <sup>b</sup>	2,2400 <sup>b</sup>	2,3279 <sup>a</sup>	29,8871 <sup>b</sup>	19,9007 <sup>c</sup>	96,3057 <sup>a</sup>	11,9129 <sup>b,c</sup>	41,9664 <sup>a</sup>
	Desvio Padrão	0,9718	0,2254	0,2664	0,1320	0,0336	2,1926	1,6385	10,6853	0,6988	3,6092
	Mínimo	17,2200	4,0800	1,2800	1,9500	2,2600	26,0400	17,1800	79,6300	10,7600	35,2200
	Máximo	20,2500	4,8700	2,0500	2,4700	2,3800	33,2600	22,9100	117,2500	13,0200	48,8900
PGT	Média	17,2483 <sup>a</sup>	4,2317 <sup>b</sup>	1,4133 <sup>b</sup>	2,2383 <sup>b</sup>	2,3050 <sup>a</sup>	28,1517 <sup>b</sup>	18,2800 <sup>c</sup>	98,9217 <sup>a</sup>	11,4333 <sup>c</sup>	41,7950 <sup>a</sup>
	Desvio Padrão	0,6509	0,2658	0,1823	0,1189	0,0226	1,9641	1,3833	30,5505	0,7515	5,4097
	Mínimo	16,4500	3,8900	1,1300	2,0700	2,2600	26,1900	16,6100	76,6000	10,7600	35,7800
	Máximo	18,3000	4,5300	1,6900	2,4100	2,3200	31,7500	20,1400	160,4100	12,8500	49,4100

Amostras em vermelho não pode ser aplicado o teste de Tukey, pois o teste de Levene's se mostrou significativo em nível de 5%. Para o teste de Tukey letras iguais não existe diferença, letras diferentes existe diferença significativa.


No MAO utilizado o parâmetro de vizinhança começou com um valor inicial igual a 4,5 diminuindo para 0,0242 e a taxa de aprendizagem iniciou em 0,1 decaindo exponencialmente para 0,00003, ao longo das épocas de treinamento. De acordo com Haykin (2001) para uma boa precisão estatística, o parâmetro da taxa de aprendizagem deve ser mantido durante a fase de convergência em um valor pequeno, da ordem de 0,01. Em todo caso não se deve permitir que ele diminua a zero, caso contrário, é possível que a grade fique presa em um estado metaestável.

A escolha da topologia da rede é fundamental para o seu bom desempenho, pois se ela é pequena demais para o banco de dados, a relação de vizinhança pode ser tão íntima entre todos os neurônios que eles podem acabar fazendo parte do mesmo grupo especializado e, como consequência, a rede pode classificar todas as amostras como um grupo só. Se a topologia da rede for grande demais serão formados muitos grupos de neurônios especializados, devido às muitas possibilidades de relações de vizinhança. Nesse caso existe uma grande dispersão dos dados, podendo prejudicar o agrupamento das amostras (BONA, *et al.*, 2012; BODT, *et al.*, 2002).

O número de épocas é outro parâmetro fundamental para o bom desempenho de uma RNA, pois quanto maior o seu valor mais vezes a rede pode analisar os dados e assim aprender melhor. No entanto, um número de épocas elevado confere maior tempo de processamento dos dados, sendo então de extrema importância que a sua escolha seja adequada para que a RNA tenha um bom desempenho e não estenda o tempo de processo, a menos que isso traga um benefício adicional (KOHONEN, 1997).

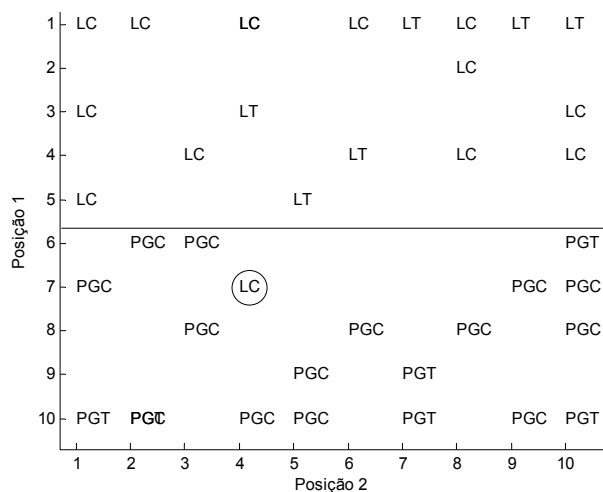
A Figura 4 mostra a relação do erro de quantização médio em função das épocas para uma topologia 10 x 10. Foi possível observar que a aplicação de 7000 épocas de treinamento foi a mais adequada para os dados analisados, o erro de quantização foi de 0,1078 e o aumento das épocas não causou diminuição do erro.

**Figura 4** – Erro de treinamento em função das épocas, dados soja




A Figura 5 mostra a distribuição das 40 amostras de soja em função do neurônio vencedor. Pode-se observar que a rede foi capaz de distinguir as amostras utilizadas. Nota-se que apenas uma amostra LC, em destaque, foi inserida em um grupo não apropriado. Também foi possível observar que tanto para o grupo de PG quanto para o grupo L, não houve agrupamento bem definido entre as amostras comuns (C) e transgênicas (T), podendo significar que as variáveis utilizadas não foram suficientes para provocar tal distinção. Mesmo quando foram testados mapas com dimensões até 20x20, tal separação não aconteceu. Isto pode estar associado ao fato dos dados de composição química depender mais do tipo de solo do que da variedade da soja.

**Figura 5** – Distribuição das amostras de acordo com o neurônio vencedor, dados soja




A Figura 6 mostra o mapa de pesos para a variável Fe onde é possível observar uma distribuição de pesos semelhantes englobando tanto as amostras L quanto as PG, o que significa que em relação a esta variável as amostras são semelhantes. Nenhuma amostra LT apresentou maiores concentrações de Fe.

**Figura 6** – Mapa de pesos da variável Fe ( $\text{mg}\cdot\text{kg}^{-1}$ ), dados soja




Nos mapas de pesos das variáveis Mn, S e Cu, Figuras 7, 8 e 9 respectivamente, as amostras L em sua grande maioria, possuem concentrações de minerais ligeiramente elevados em relação as PG. Mas como esse aumento é pouco pronunciado considera-se que estas variáveis possuem pouca influencia na formação dos grupos. O Mn, Figura 7, por exemplo, apresenta uma quantidade de amostras L no canto superior esquerdo do mapa que se destacam por possuírem maior concentração deste mineral. No entanto, a maioria das amostras L e PG estão localizadas em uma região de peso semelhante (azul).

**Figura 7** – Mapa de pesos da variável Mn ( $\text{mg}\cdot\text{kg}^{-1}$ ), dados soja




Da mesma forma é observado que no mapa de pesos do S e Cu, Figura 8 e 9 respectivamente, a maior parte das amostras está localizada em uma região de pesos com pouca diferença, salvo por poucas amostras L que se destacam por apresentarem concentrações mais elevadas que as demais.

**Figura 8** – Mapa de pesos da variável S ( $\text{g}\cdot\text{kg}^{-1}$ ), dados soja




**Figura 9** – Mapa de pesos da variável Cu ( $\text{mg kg}^{-1}$ ), dados soja



O mapa de pesos para a concentração de B, Figura 10, é heterogêneo, no entanto estas diferenças não seguem uma lógica em relação à distribuição das amostras. É possível afirmar que, neste caso específico, a absorção deste mineral pela soja não está relacionado com a sua disponibilidade no solo, uma vez que tanto para amostras PG quanto L houve muita variação de concentração dos minerais.


**Figura 10** – Mapa de pesos da variável B ( $\text{mg kg}^{-1}$ ), dados soja



Mesmo tendo apresentado pouca influencia na classificação das amostras não se pode afirmar que o Fe, Mn, S, Cu e B não possuem nenhuma importância para a classificação destas amostras, pois em testes realizados, onde estes elementos foram excluídos do banco de dados, a distribuição das amostras não forneceu dois grupos bem definidos.

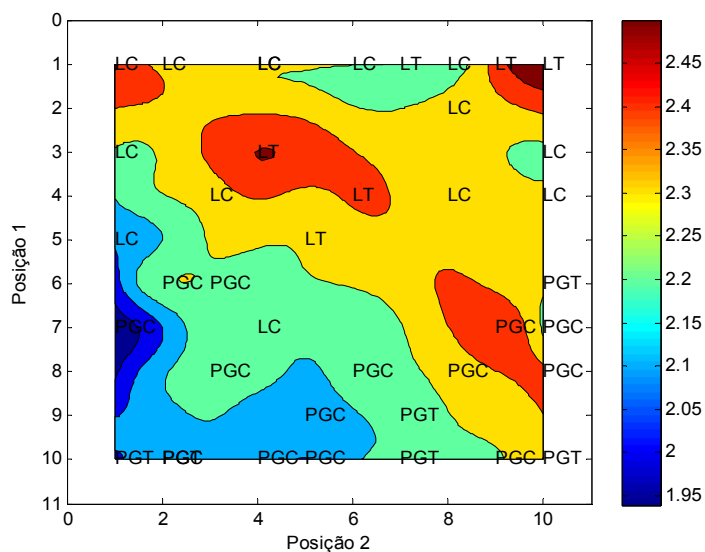
Os mapas de peso para os elementos P, Mg e K demonstram maior influência para a formação dos grupos. Para o P, Figura 11, por exemplo, a grande maioria das amostras de L, variam de 4,6 a 6 g kg<sup>-1</sup>, enquanto que as amostras PG variam de 3,8 a 4,6 g kg<sup>-1</sup>. Embora ainda exista uma região intermediária, em torno de 4,6 g kg<sup>-1</sup>, onde se localizam tanto amostras L quanto PG, pode-se afirmar que as sojas plantadas em PG possuem menor concentração de P em relação às de L.

**Figura 11** – Mapa de pesos da variável P (g kg<sup>-1</sup>), dados soja




Para o Mg e o K, Figuras 12 e 13 respectivamente, a diferença de concentração entre L e PG é mais acentuada. Nestes casos não existem valores de concentração intermediária que englobe amostras das duas regiões. As amostras de L possuem maiores concentrações de Mg e K em relação às de PG porém, existe um pequeno número de amostras de PG, em sua maioria PGC, que possui concentração maior de Mg assemelhando-se assim às amostras de L. Além disso, um outro grupo ainda menor de PG possui altas concentrações de K se adequando melhor ao grupo L.

**Figura 12** – Mapa de pesos da variável Mg ( $\text{g kg}^{-1}$ ), dados soja



**Figura 13** – Mapa de pesos da variável K ( $\text{g kg}^{-1}$ ), dados soja




Quando se analisa o mapa de distribuição das amostras, Figura 5, além de extrair a informação quanto à separação de grupos, como observado no caso dos grupos L e PG, pode-se também relacionar a semelhança das propriedades em função das distâncias entre eles. Embora este tipo de interpretação seja mais útil, quando se analisa dados onde são formados mais de 2 grupos, neste caso, é possível concluir que as amostras que ocupam uma região intermediária do mapa, próximas a linha de divisão, possuem semelhanças, caso contrário existiria uma distância maior, e vazia, entre os grupos.

Analisando por este aspecto pode-se dizer que todas as variáveis já discutidas tiveram muita influência na aproximação dos grupos. Mas as variáveis Ca e Zn foram as que mais contribuíram para a classificação das amostras, em dois grupos definidos. De acordo com as Figuras 14 e 15, mapas de pesos para Ca e Zn respectivamente, existe uma grande diferença de concentração destes elementos entre as sojas de L e de PG.


Na Figura 14 é possível observar que as amostras de L possuem concentrações de Ca maior ou igual a  $2 \text{ g kg}^{-1}$ , com exceção de uma amostra LC que se encontra em uma região em torno de  $1,7 \text{ g kg}^{-1}$  que corresponde a concentrações que caracterizam as amostras de PG. Enquanto que as amostras de PG possuem concentrações de Ca menor ou igual a  $1,7 \text{ g kg}^{-1}$ .

Para o caso do Zn, Figura 15, as amostras L possuem valores maiores ou igual a  $34 \text{ mg kg}^{-1}$ , enquanto que as de PG possuem concentrações menores ou igual a  $32 \text{ mg kg}^{-1}$ .

**Figura 14** – Mapa de pesos da variável Ca ( $\text{g kg}^{-1}$ ), dados soja



**Figura 15** – Mapa de pesos da variável Zn ( $\text{mg.kg}^{-1}$ ), dados soja



Outra relação muito importante que se pode retirar destas análises é que, com exceção dos elementos Fe e B, todos os outros revelaram uma tendência mesmo que sutil, como no caso do Mn, S e Cu, das amostras de L apresentarem maiores concentrações de compostos inorgânicos em relação à PG, estando, portanto, relacionada com a concentração destes minerais no solo. A análise dos mapas topológicos não apontou evidências que possam indicar que a capacidade de absorção destes minerais esteja relacionada com o fato da soja ser transgênica ou não.

Nas análises estatísticas convencionais, Tabelas 1 e 2, constatou-se que os parâmetros que diferenciam as cidades de origem das amostras de soja foram, P, K, Mg e Cu, já no MAO constatou que o Cu não possui tanta influencia quanto os demais e que apesar de P, K e Mg influenciarem na separação das amostras na rede, os parâmetros mais importantes foram Ca e Zn. Esta diferença de resultados existe porque a rede não se baseia em estudo de médias como acontece no teste deTukey.

O MAO constatou que nenhum dos parâmetros possui tendência em diferenciar amostras transgênicas e comuns enquanto que o teste de Tukey indica que as variáveis K e Mg podem diferenciá-las.

## 5.2 CAFÉ

A tabela de dados utilizados está apresentada no Anexo B, e a Tabela 3 mostra como foram agrupadas as cidades em suas regiões. As cidades que compõem uma determinada região não são necessariamente próximas geograficamente. A classificação de regiões, em relação às cidades, foi realizada levando-se em consideração as semelhanças do clima e temperatura de cada cidade. Ainda nesta tabela são apresentadas as letras que representam cada cidade seguida do número de amostras analisadas.

**Tabela 3** – Divisão da amostragem das cidades em regiões, 172 amostras

Municípios		
Região A	Região B	Região C
Francisco Alves ( <b>a</b> , 9)	Nova Esperança ( <b>f</b> , 20)	Guapirama ( <b>k</b> , 10)
Jesuítas ( <b>b</b> , 3)	Jundiaí do Sul ( <b>g</b> , 6)	Joaquim Távora ( <b>l</b> , 9)
São Jorge do Patrocínio ( <b>c</b> , 17)	Londrina ( <b>h</b> , 20)	Carlópolis ( <b>m</b> , 7)
Brasilândia do Sul ( <b>d</b> , 10)	Uraí ( <b>i</b> , 11)	Jacarezinho ( <b>n</b> , 18)
Iporã ( <b>e</b> , 3)	Santa Mariana ( <b>j</b> , 12)	Abatiá ( <b>o</b> , 11)
		Conselheiro Mairinck ( <b>p</b> , 6)

Entre parênteses o código da cidade e a quantidade de amostras analisadas.

Os dados estatísticos básicos para o conjunto de dados é apresentado na Tabela 4. Também para este caso foi aplicado o teste de Levene's. No entanto, como ele resultou significativo para todas as variáveis não é recomendado a aplicação do teste de Tukey (CALADO e MONTGOMERY, 2003). Portanto, não foi possível utilizar métodos estatísticos convencionais para avaliar a existência ou não de diferenças entre os grupos estudados.


**Tabela 4** – Valor de máximo, mínimo, média e desvio padrão para os dados de café em relação às regiões de origem

Amostras	Parâmetro	P (g kg <sup>-1</sup> )	K (g kg <sup>-1</sup> )	Ca (g kg <sup>-1</sup> )	Mg (g kg <sup>-1</sup> )	Cu (mg kg <sup>-1</sup> )	Zn (mg kg <sup>-1</sup> )	B (mg kg <sup>-1</sup> )	Mn (mg kg <sup>-1</sup> )	Fe (mg kg <sup>-1</sup> )	S (g kg <sup>-1</sup> )
Região A	Média	1,82	18,33	1,37	2,01	16,74	8,14	17,51	26,51	31,61	1,58
	Desvio Padrão	0,30	2,29	0,20	0,26	1,86	2,57	8,84	6,82	11,46	0,19
	Mínimo	0,93	9,50	0,73	1,16	11,30	4,20	5,60	15,50	16,08	0,88
	Máximo	2,50	22,70	1,86	2,44	19,30	15,20	41,70	41,70	93,77	1,81
Região B	Média	1,78	16,26	1,39	1,93	15,17	8,52	14,93	37,11	30,56	1,50
	Desvio Padrão	0,31	1,99	0,45	0,16	2,81	3,06	10,80	20,70	8,09	0,20
	Mínimo	1,41	10,50	0,82	1,57	10,20	4,90	5,10	14,98	20,09	1,17
	Máximo	2,82	20,40	3,10	2,26	22,30	22,08	60,80	109,20	56,80	2,11
Região C	Média	1,91	17,61	1,68	1,96	15,58	10,54	11,65	35,46	39,67	1,67
	Desvio Padrão	0,56	1,25	0,78	0,20	2,27	5,18	3,14	14,64	19,31	0,40
	Mínimo	1,34	12,60	0,84	1,62	11,90	4,50	6,60	16,00	20,20	1,30
	Máximo	3,07	19,20	4,09	2,49	20,50	27,60	20,00	68,40	104,20	2,55

O melhor desempenho da rede MAO utilizada foi obtido utilizando uma topologia de 12x12 e 8000 épocas. O parâmetro de vizinhança iniciou em 5,5 e decaiu até atingir o valor de 0,007, já a taxa de aprendizagem iniciou em 0,1 e diminuiu até atingir o valor de 0,00001.


A Figura 16 mostra a relação do erro de quantização médio em função das épocas. Em torno de 7000 épocas houve a estabilização do erro. Ao final das 8000 épocas o erro obtido foi de 0,4420 e o aumento das épocas não causou diminuição do erro nem mesmo melhorou o desempenho da rede.

**Figura 16** – Erro de treinamento em função das épocas, (dados café, 172 amostras e 10 variáveis)



A Figura 17 mostra a distribuição das 172 amostras de acordo com o neurônio vencedor. Existe uma tendência de agrupamento apenas para a região A, formada ao longo da diagonal do mapa, do canto superior esquerdo ao canto inferior direito. Nota-se que não houve distribuição bem definida para os demais grupos de regiões. Isto pode ter sido ocasionado pela forma com que as cidades foram agrupadas em regiões, baseadas em seu clima e temperatura, e não no tipo de solo, pois é sabido que a quantidade de minerais na planta está relacionada com a disponibilidade dos mesmos no solo.


**Figura 17** – Distribuição das amostras de acordo com o neurônio vencedor, (dados café, 172 amostras e 10 variáveis)



Para melhor compreensão dos resultados gerados pela rede, os gráficos de distribuição para cada região isoladamente, são apresentados a seguir. De acordo com a Figura 18a, vê-se que as amostras classificadas como região A, sendo elas 42 no total, estão espalhadas pelo mapa, não formam um grupo bem definido. Mas quando se analisa a Figura 18b percebe-se que as cidades **a**, **d** e **e**, formam 3 grupos que embora sejam distintos, não são muito diferentes entre si devido a proximidade dos mesmos e, além disso, existe apenas uma amostra da cidade **a** e uma da cidade **d** que não se encaixam nos seus respectivos grupos.

As amostras da cidade **c** estão dispersas no mapa, o que indica que a rede não foi capaz de reconhecê-las como amostras iguais. Isso pode significar que as variáveis escolhidas não são suficientes para reconhecimento de um padrão para estas cidades.

**Figura 18** – Distribuição das amostras de acordo com o neurônio vencedor: a) para região A e b) para as cidades que compõem esta região, (dados café, 49 amostras e 10 variáveis)




Na Figura 19, são apresentados os mapas de peso para todas as variáveis, sobrepostos pelo mapa de distribuição das cidades da região A. Os mapas das variáveis, Ca, Fe, K, Mn, Zn e B representados pela Figura 19a, c, d, f, i e j respectivamente, apresentam pouca influência na separação das amostras devido a pequena diferença de pesos. Na Figura 19b, que representa o mapa de peso para a variável Cu vemos que as cidades **a**, **d** e **e** ocupam uma região de maior concentração enquanto que as amostras da cidade **b**, em sua totalidade, e **c**, em sua maioria, se localizam em uma região de concentração menor.

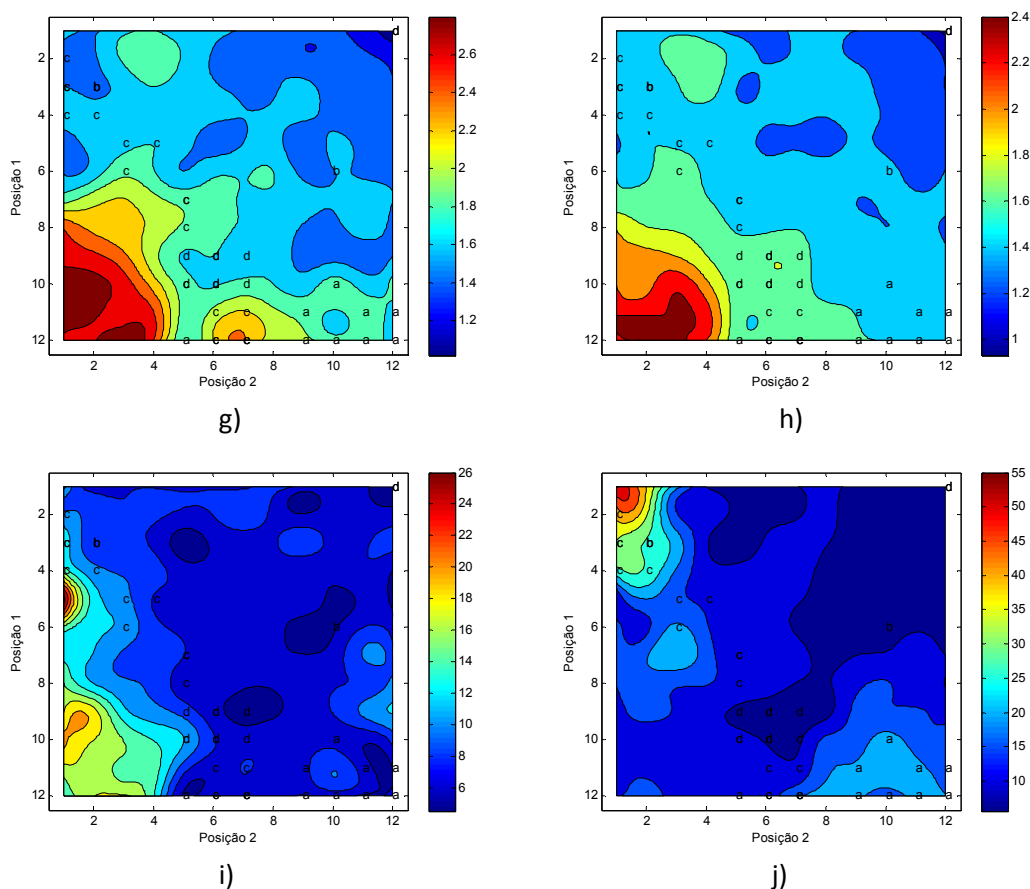
A variável Mg, Figura 19e foi claramente o responsável pela formação dos grupos **d** e **e**, pois todas suas amostras ocupam uma região de alta concentração de Mg, diferenciando-as das demais cidades.

O mapa de peso para a variável P, Figura 19g, não apresentou um padrão bem definido. A maioria das amostras das cidades encontra-se em uma parte (verde) do mapa de concentração semelhante. A informação relevante neste caso é em relação à cidade **e**, pois ela foi a única cidade classificada em uma região de alta concentração, assim podemos dizer que o P é a variável que diferencia a cidade **e**, das demais.

O mapa para o S, Figura 19h, também mostra ser uma variável auxilia na definição do grupo da cidade **d** e **e**, pois estas amostras estão localizadas em uma região (verde), de maior concentração no mapa, diferente das demais que se situam na região (azul clara) de concentração menor.


**Figura 19** – Distribuição das cidades da região A sobre o mapa de pesos das variáveis: a) Ca ( $\text{g kg}^{-1}$ ), b) Cu ( $\text{mg kg}^{-1}$ ), c) Fe ( $\text{mg kg}^{-1}$ ), d) K ( $\text{g kg}^{-1}$ ), e) Mg ( $\text{g kg}^{-1}$ ), f) Mn ( $\text{mg kg}^{-1}$ ), g) P ( $\text{g kg}^{-1}$ ), h) S ( $\text{g kg}^{-1}$ ), i) Zn ( $\text{mg kg}^{-1}$ ) e j) B ( $\text{mg kg}^{-1}$ ), (dados café, 49 amostras e 10 variáveis)





As amostras da região B foram as que mais se distribuíram por toda extensão do mapa, Figura 20a, sendo que esta região contém a maior quantidade de amostras, 69 no total. As cidades desta região que estão mais dispersas são as *i* e *f*. As cidades *g*, *h* e *j* formam dois grupos diferentes, o primeiro composto pelas cidades *g* e *h*, situados no canto superior direito em destaque, e o segundo formado pela cidade *j* também em destaque, sendo que apenas uma amostra da cidade *j* não está agrupada corretamente. Estudando a relação de vizinhança entre estes grupos pode-se concluir que eles não são semelhantes, ao contrário dos grupos da região A, pois a distância existente entre os dois grupos formados é bem grande, estando localizados em pontas opostas do mapa em diagonal.

**Figura 20** – Distribuição das amostras de acordo com o neurônio vencedor: a) para região B e b) para as cidades que compõem esta região, (dados café, 69 amostras e 10 variáveis)





De acordo com os mapas de pesos para as cidades da região B, das variáveis Fe, Mn, Zn e B, representadas pela Figura 21c, f, i e j respectivamente, não foi observada separação das amostras de cidades diferentes, pois todas possuem pesos muito semelhantes. O mapa de peso para o Ca, Figura 21a, mostra que a cidade *j* se localiza em uma região com concentração ligeiramente maior em relação às demais.

Para as variáveis, Cu, P e S, Figura 21b, g e h, as amostras das cidades *g* e *h* se concentram em regiões de menor concentração no mapa, enquanto que a cidade *j* se localiza em uma região de concentração maior. As amostras das cidades *i* e *f* estão localizadas tanto em regiões de altas, intermediária e baixas concentrações, ou seja, não possuem um padrão em relação a estas variáveis.


No mapa da Figura 21d, para o K, a maioria das amostras das cidades *g* e *h* novamente estão situadas em regiões de menor concentração salvo por 3 amostras *h* e 1 *g* que estão com a concentração um pouco acima das demais, e mais uma vez a cidade *j* está em uma região de concentração maior. O mapa de peso do Mg, Figura 21e, é heterogêneo então não contribui para a formação de um grupo, uma vez que as amostras de todas as cidades localizam-se tanto em regiões de altas como baixas concentrações variando de 1,5 a 2 g kg<sup>-1</sup>.

**Figura 21** – Distribuição das cidades da região B sobre o mapa de pesos das variáveis: a) Ca ( $\text{g kg}^{-1}$ ), b) Cu ( $\text{mg kg}^{-1}$ ), c) Fe ( $\text{mg kg}^{-1}$ ), d) K ( $\text{g kg}^{-1}$ ), e) Mg ( $\text{g kg}^{-1}$ ), f) Mn ( $\text{mg kg}^{-1}$ ), g) P ( $\text{g kg}^{-1}$ ), h) S ( $\text{g kg}^{-1}$ ), i) Zn ( $\text{mg kg}^{-1}$ ) e j) B ( $\text{mg kg}^{-1}$ ), (dados café, 69 amostras e 10 variáveis)







g)



h)



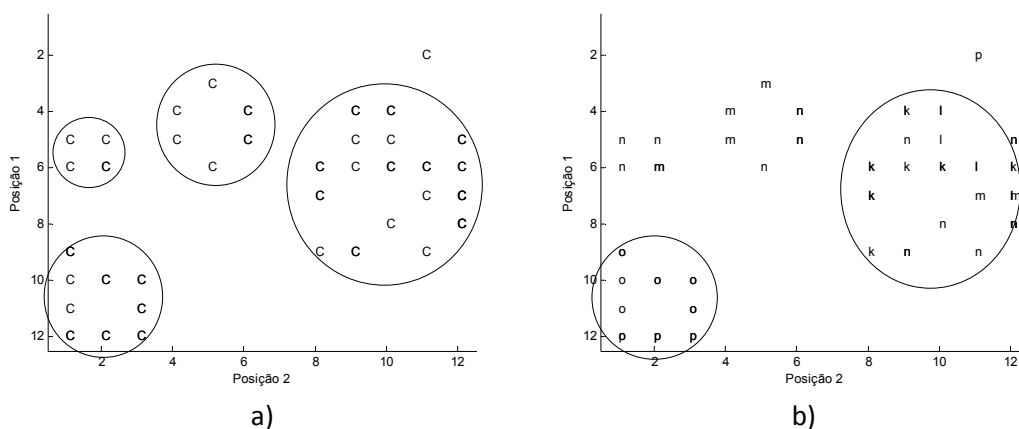
i)



j)

A região C é composta por 61 amostras e, quando se analisa a Figura 22a, nota-se que a dispersão das amostras se deu de maneira diferente ao das regiões A e B. O mapa, Figura 22a, indica a formação de 4 grupos diferentes, destacados no gráfico. Através da Figura 22b, conclui-se que existem 2 grupos bem definidos, um composto pelas cidades **o** e **p**, exceto por uma amostra **p** que não pertence a nenhum grupo, e outro composto pelas cidades **k** e **l** e algumas amostras das cidades de **m** e **n**. No entanto as cidades **m** e **n** estão espalhadas pelo mapa.

**Figura 22** – Distribuição das amostras de acordo com o neurônio vencedor: a) para região C e b) para as cidades que compõem esta região, (dados café, 61 amostras e 10 variáveis)



De acordo com o mapa topológico, para esta região, os únicos componentes inorgânicos que não contribuíram para formação dos grupos foram os K e B, Figura 23d e j, respectivamente. O mapa da variável K revela uma distribuição heterogênea das amostras, que não segue um padrão. Já o mapa do B mostra uma distribuição de concentração homogênea, ou seja, indica que todas as amostras são semelhantes.

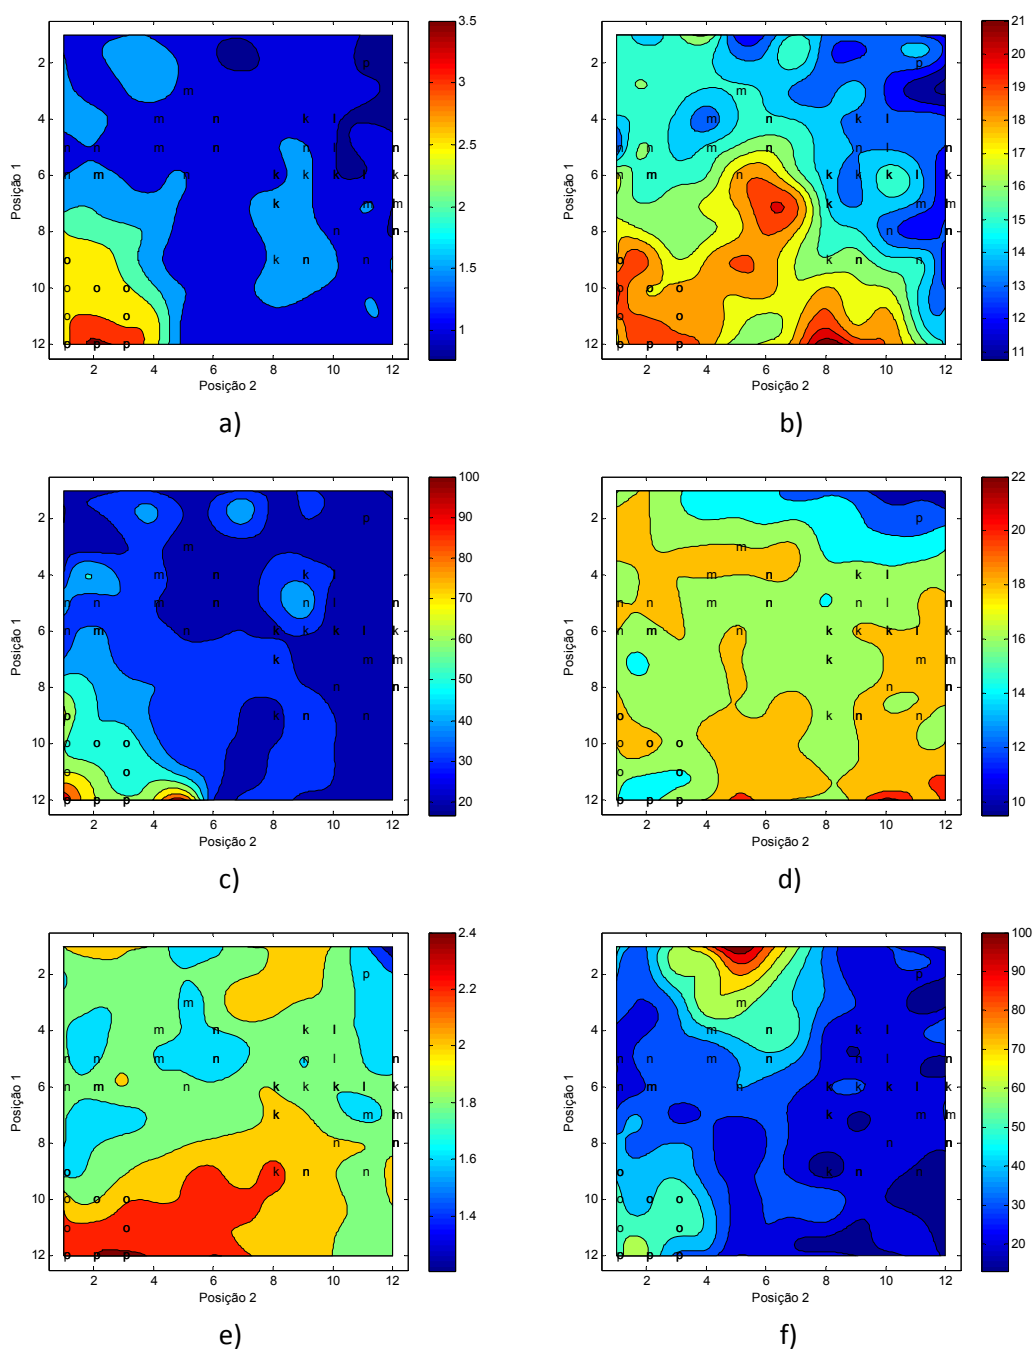
As variáveis Ca, P e S, Figura 23a, g e h, respectivamente, foram responsáveis por definir o grupo formado pelas das cidades **o** e **p**, visto que nos 3 casos este grupo se encontra em uma região de concentração bem maior que as demais amostras. Estas se encontram distribuídas em uma região de concentração com poucas variações. Para o mapa da variável S, Figura 23h, a cidade **l**, tem concentração ligeiramente menor em relação as da cidade **k** mas devido aos pesos semelhantes isto não é suficiente para classificarmos como sendo grupos diferentes.

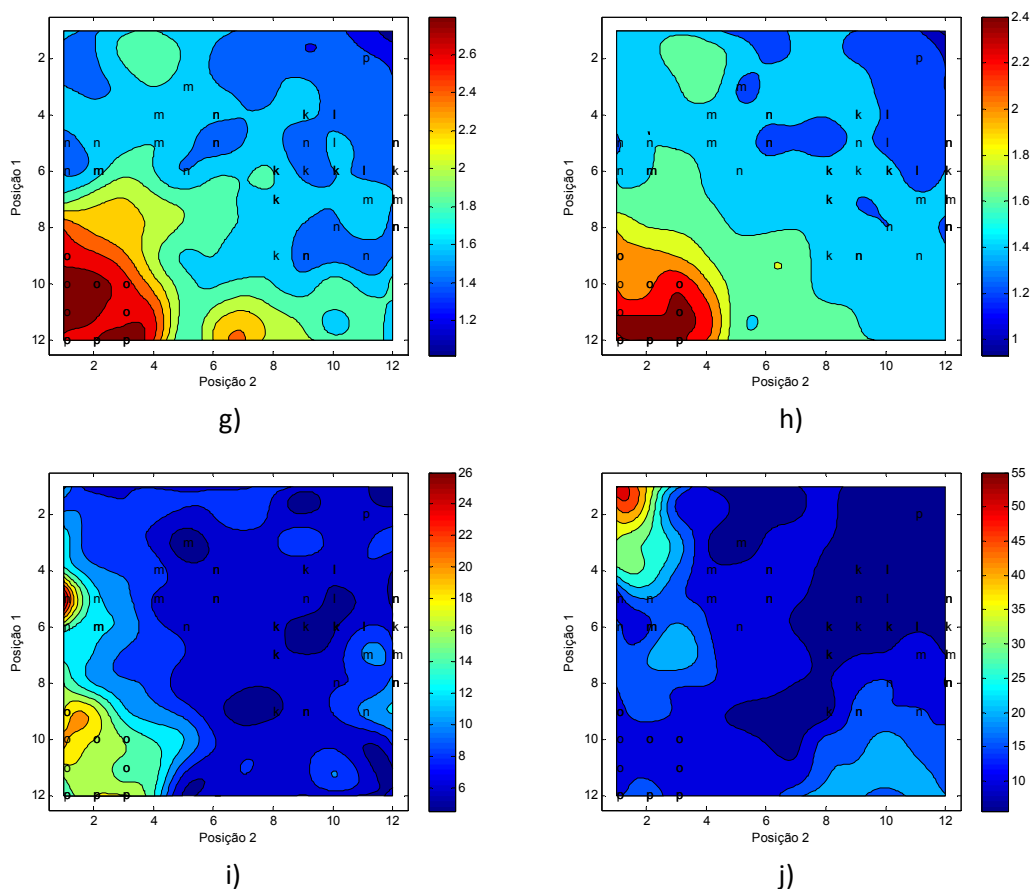
A variável Cu, Figura 23b, além de definir o grupo das cidades **o** e **p**, também define o das cidades **k** e **l**. O primeiro grupo se localiza em uma região de alta concentração, em torno de  $19 \text{ mg kg}^{-1}$ , e o segundo se localiza em uma região de concentração média em torno de  $13 \text{ mg kg}^{-1}$ . As amostras das cidades **m** e **n**, não apresentam o mesmo comportamento, pois elas se localizam tanto em regiões de alta quanto de baixas concentrações.

As variáveis Fe, Mn e Zn, Figura 23c, f e i respectivamente, também contribuem para diferenciar o grupo das cidades **o** e **p** das demais, no entanto a

diferença de peso é menos acentuada. O mapa do Mg, Figura 23e, também diferencia os dois grupos mas alguma amostras de ambos os grupos coexistem em uma região de concentração semelhante.

**Figura 23** – Distribuição das cidades da região C sobre o mapa de pesos das variáveis: a) Ca ( $\text{g kg}^{-1}$ ), b) Cu ( $\text{mg kg}^{-1}$ ), c) Fe ( $\text{mg kg}^{-1}$ ), d) K ( $\text{g kg}^{-1}$ ), e) Mg ( $\text{g kg}^{-1}$ ), f) Mn ( $\text{mg kg}^{-1}$ ), g) P ( $\text{g kg}^{-1}$ ), h) S ( $\text{g kg}^{-1}$ ), i) Zn ( $\text{mg kg}^{-1}$ ) e j) B ( $\text{mg kg}^{-1}$ ), (dados café, 61 amostras e 10 variáveis)






A única variável que não influenciou simultaneamente nos 3 casos foi o B. Foram realizados testes excluindo esta variável, porém isto não causou melhora dos resultados obtidos pela rede. Assim conclui-se que as cidades que não foram agrupadas pelas análises realmente não possuem um padrão em relação às variáveis utilizadas.

A Figura 24 mostra como seria a distribuição das amostras sem as cidades que não puderam ser agrupadas, sendo elas as cidades *b*, *c*, *i*, *f*, *m* e *n*. Porém não é possível analisar esta figura desta forma, pois as demais cidades excluídas influenciaram no processo de interpretação e classificação da rede.

**Figura 24** – Distribuição das amostras de acordo com o neurônio vencedor para as cidades **a, d, e, g, h, j, k, l, o e p**



Um novo treinamento foi realizado excluindo as cidades que não puderam ser classificadas pela rede utilizando a concentração de componentes inorgânicos. O novo banco de dados agora é formado pelas cidades **a, d, e, g, h, j, k, l, o e p**, totalizando 96 amostras. A Tabela 5 mostra as cidades que compõem o novo banco de dados.

**Tabela 5** – Divisão da amostragem das cidades em regiões, 96 amostras

Municípios		
Região A	Região B	Região C
Francisco Alves ( <b>a</b> , 9)	Jundiá do Sul ( <b>g</b> , 6)	Guapirama ( <b>k</b> , 10)
Brasilândia do Sul ( <b>d</b> , 10)	Londrina ( <b>h</b> , 20)	Joaquim Távora ( <b>l</b> , 9)
Iporã ( <b>e</b> , 3)	Santa Mariana ( <b>j</b> , 12)	Abatiá ( <b>o</b> , 11)
		Conselheiro Mairinck ( <b>p</b> , 6)

Entre parênteses o código da cidade e a quantidade de amostras analisadas.

De acordo com a Tabela 6, de dados estatísticos convencionais para este novo banco de dados, as únicas variáveis em que foi recomendado a aplicação do teste de Tukey, foram K, Mg e Cu e, nos três casos, o teste indica que existe diferença significativa da região B com as demais e que não existe diferença da região A em relação a C.

**Tabela 6** – Valor de máximo, mínimo, média e desvio padrão para os dados de café em relação às regiões de origem, sem levar em consideração as cidades, **b, c, f, i, m e n**


Amostras	Parâmetro	P (g kg <sup>-1</sup> )	K (g kg <sup>-1</sup> )	Ca (g kg <sup>-1</sup> )	Mg (g kg <sup>-1</sup> )	Cu (mg kg <sup>-1</sup> )	Zn (mg kg <sup>-1</sup> )	B (mg kg <sup>-1</sup> )	Mn (mg kg <sup>-1</sup> )	Fe (mg kg <sup>-1</sup> )	S (g kg <sup>-1</sup> )
Região A	Média	1,82 <sup>b</sup>	18,24 <sup>b</sup>	1,32 <sup>b</sup>	2,05 <sup>b</sup>	17,15 <sup>b</sup>	6,75 <sup>b</sup>	14,47 <sup>a</sup>	23,29 <sup>a</sup>	31,96 <sup>b</sup>	1,58 <sup>b</sup>
	Desvio Padrão	0,35	3,10	0,21	0,30	2,24	1,48	6,25	6,46	14,86	0,25
	Mínimo	0,93	9,50	0,73	1,16	11,30	4,20	5,60	15,50	16,08	0,88
	Máximo	2,50	22,70	1,64	2,29	19,30	10,77	24,10	35,57	93,77	1,81
Região B	Média	1,76 <sup>b</sup>	15,39 <sup>a</sup>	1,41 <sup>b</sup>	1,87 <sup>a</sup>	14,27 <sup>a</sup>	9,03 <sup>b</sup>	10,96 <sup>b</sup>	38,88 <sup>b</sup>	32,13 <sup>b</sup>	1,49 <sup>b</sup>
	Desvio Padrão	0,40	1,92	0,59	0,16	2,36	3,33	5,34	22,55	10,03	0,24
	Mínimo	1,41	10,50	0,82	1,57	10,20	5,60	5,10	14,98	20,09	1,17
	Máximo	2,82	19,20	3,10	2,26	22,08	22,08	29,40	109,20	56,80	2,11
Região C	Média	2,15 <sup>a</sup>	17,28 <sup>b</sup>	1,93 <sup>a</sup>	2,04 <sup>b</sup>	16,07 <sup>b</sup>	11,28 <sup>a</sup>	10,64 <sup>b</sup>	37,61 <sup>b</sup>	45,98 <sup>a</sup>	1,83 <sup>a</sup>
	Desvio Padrão	0,62	1,47	0,91	0,21	2,51	5,41	2,71	15,03	22,18	0,45
	Mínimo	1,34	12,60	0,85	1,64	11,90	4,80	6,60	16,00	20,20	1,30
	Máximo	3,07	19,20	4,09	2,49	20,50	19,95	16,90	68,40	104,20	2,55

Amostras em vermelho não pode ser aplicado o teste Tukey, pois o teste de Levene's se mostrou significativo em nível de 5%. Para o teste Tukey letras iguais não existe diferença, letras diferentes existe diferença significativa.

O melhor desempenho da rede MAO utilizada foi obtido com uma topologia de 10x10 e 8000 épocas. O parâmetro de vizinhança iniciou em 4,5 e decaiu até atingir o valor de 0,0242, a taxa de aprendizagem iniciou em 0,1 e diminuiu até atingir o valor de 0,00003.

A Figura 25 mostra a relação do erro de quantização médio com as épocas. Em torno de 7000 épocas houve a estabilização do erro e, ao final das 8000 épocas o seu valor foi de 0,3271. O aumento das épocas não causou diminuição do erro e nem mesmo melhorou o desempenho da rede.

**Figura 25** – Erro de treinamento em função das épocas, (dados café, 96 amostras 10 variáveis)




No mapa de distribuição das amostras para regiões, Figura 26a, nota-se que a região A se encontra bem agrupada, a região B também forma um grupo na parte inferior da mapa e o grupo da região C ocupa o espaço entre os grupos das regiões B e A. Porém quando se analisa o mapa de distribuição, em relação às cidades, é possível dividir as amostras em 6 grupos definidos destacados na Figura 26b. Além disso, pode-se concluir que as amostras das cidades **a** e **e** possuem maiores relações de semelhança entre si quando comparadas com as relações existentes das amostras das cidades **a** e **d** ou das **e** e **d**.

As amostras das cidades **g** e **h**, da região B, possuem mais semelhanças com as **k** e **l**, que pertencem à região C, do que com a cidade **j** que faz

parte da região B. As cidade **o** e **p**, região C, por sua vez possuem mais semelhanças com a cidade **j**, região B, do que com as cidades **k** e **l** da região C.

Novamente percebe-se que a análise em relação as regiões de origem destas amostras não é a mais adequada, devendo-se portanto estudar estes agrupamentos em relação às cidades de origem. A análise estatística em relação aos grupos dividido em cidades, anexo C, mostrou que o teste de Tukey não foi recomendado para nenhum caso, pois o teste de Levene's foi significativo para todas as variáveis.

**Figura 26** – Distribuição das amostras de acordo com o neurônio vencedor: a) em relação às regiões e b) em relação às cidades, (dados café, 96 amostras 10 variáveis)



Os mapas de pesos as variáveis Ca, Fe e Zn, Figura 27a, c e i respectivamente, mostraram ser muito influentes na classificação das cidades **o** e **p**, pois nestes casos essas cidades se destacaram por apresentar altas concentrações destes componentes, ao contrário das demais cidades que apresentam concentrações mais baixas e muito semelhantes entre si. Além disso, o Ca, também é responsável por diferenciar as amostras da cidade **j**, que se localizam em uma região de concentração intermediária.

A Figura 27b, mostra o mapa de pesos para a variável Cu, onde se pôde verificar que as amostras das cidades **g**, **h**, **k** e **l**, quase na sua totalidade, se encontram na região de menor concentração, variando de 11 a 15,5 mg kg<sup>-1</sup>, enquanto que a cidade **j** se encontra em uma região de concentração um pouco maior entre 15, e 16,5 mg kg<sup>-1</sup> aproximadamente, e as cidades **a**, **d**, **e**, **o** e **p**, variam entre 17 e 19 mg kg<sup>-1</sup>.

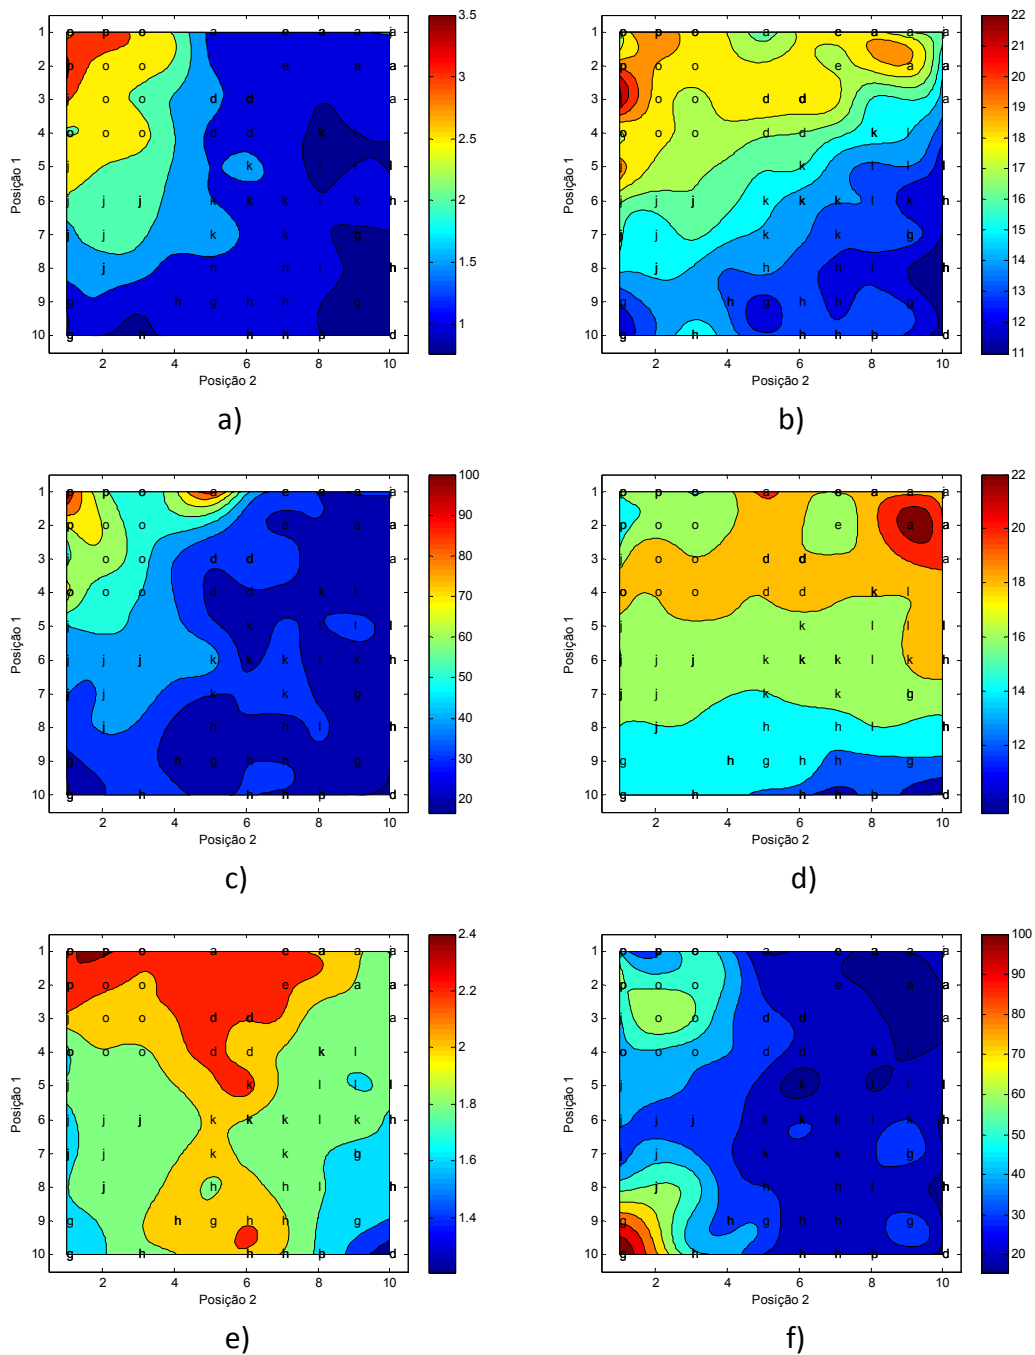
Apesar do mapa da variável K, Figura 27d, não ser muito influente na formação dos grupos quando comparada às demais variáveis, existe uma informação muito interessante neste mapa. As cidades **g**, **h**, **k** e **l** formam um único grupo, mas de acordo com esta variável, em especial, existe uma diferença entre as amostras das cidades **g** e **h**, de menor concentração, em relação às das **k** e **l**, de maior concentração.


As variáveis Mg e Mn, Figura 27e e f, também não foram tão influentes na formação dos grupos. O mapa de peso para o Mg não indica uma relação coerente com os grupos formados. Já para o mapa do Mn o mapa engloba quase totalmente as amostras em uma região de concentração semelhante, com exceção de duas amostras da cidade **g** que se destacam um pouco acima da média, bem como uma amostra da cidade **o**.

Os mapas do P e S, Figura 27g e h, destacam as cidades **o** e **p**, com concentrações mais elevadas destes componentes, se diferenciam das cidades **a**, **g**, **h**, **k** e **l**, de concentrações menores, e da cidade **j** com concentrações intermediárias. No mapa do P, além disso, houve também um pequeno destaque nas amostras da cidade **e**, que possuem concentração mais elevada. O mapa de peso para a variável S também foi responsável por destacar as cidades **e** e **d**, cuja amostras são mais concentradas que as das cidades **a**, **g**, **h**, **k** e **l** e menos que as das **o** e **p**.

A variável B, Figura 27j, influenciou apenas na formação do grupo das amostras **a**, de concentração em torno de  $22 \text{ mg kg}^{-1}$ , pois as demais possuem concentração menor e são semelhantes entre si.

**Figura 27** – Distribuição das cidades selecionadas sobre o mapa de pesos das variáveis: a) Ca ( $\text{g kg}^{-1}$ ), b) Cu ( $\text{mg kg}^{-1}$ ), c) Fe ( $\text{mg kg}^{-1}$ ), d) K ( $\text{g kg}^{-1}$ ), e) Mg ( $\text{g kg}^{-1}$ ), f) Mn ( $\text{mg kg}^{-1}$ ), g) P ( $\text{g kg}^{-1}$ ), h) S ( $\text{g kg}^{-1}$ ), i) Zn ( $\text{mg kg}^{-1}$ ) e j) B ( $\text{mg kg}^{-1}$ ), (dados café, 96 amostras 10 variáveis)






A retirada das amostras que não puderam ser agrupadas, nas primeiras análises da rede, melhora o desempenho da mesma. Isto não significa que a rede falhou inicialmente mas, que aquelas cidades não podem ser agrupadas baseadas nas concentrações de componentes inorgânicos. A nova seleção de dados, juntamente com a nova análise dos mapas de pesos, mostraram que os componentes inorgânicos menos relevantes para o resultado da rede foram K, Mg e Mn. Todas as demais variáveis contribuíram de alguma forma para o resultado obtido pela rede.

Foi realizado um novo estudo retirando-se as variáveis. Neste caso utilizou-se topologia de 10x10 e 8000 épocas. O parâmetro de vizinhança iniciou em 4,5 e decaiu até atingir o valor de 0,0242, a taxa de aprendizagem iniciou em 0,1 e diminuiu até atingir o valor de 0,00003.

A Figura 28 mostra a relação do erro de quantização médio com as épocas. Em torno de 7000 épocas houve a estabilização do erro e, ao final das 8000 épocas o erro obtido foi de 0,1556. O aumento das épocas não causou diminuição do erro nem mesmo melhorou o desempenho da rede.

**Figura 28** – Gráfico do erro de treinamento em função das épocas, (dados café, 96 amostras 7 variáveis)




Na Figura 29 são apresentados os mapas de distribuição do treinamento anterior onde foram utilizadas as 10 variáveis, Figura 29a, bem como o tratamento atual com apenas 7 variáveis, Figura 29b.

Os grupos formados na Figura 29b foram os mesmos do treinamento anterior, no entanto as duas amostras da cidade **g**, que se encontravam distantes do seu grupo ideal, neste caso não estão. Porém a relação de vizinhança aparentemente não foi preservada. O grupo da cidade **d**, por exemplo, no treinamento com 10 variáveis, é semelhante ao grupo da cidade **e** e da cidade **a**. Esta relação não é encontrada no mapas de peso para 7 variáveis. A relação de vizinhança para a cidade **a** também sofreu mudanças a princípio esta cidade possuía menos semelhança com o grupo da cidade **j**. Já quando houve redução das variáveis, Figura 29b, a cidade **j** se tornou muito semelhante à cidade **a**.


É comum que à medida que processamos os dados na rede ela pode rotacionar as amostras no mapa de distribuição, porém ela deve preservar as informações obtidas. Outro fenômeno que também pode ocorrer é o de torção das amostras que podem indicar uma falsa mudança na relação de vizinhança ( BODT, *et al.*, 2002).

Uma maneira de verificar se ocorre uma torção do mapa ou se realmente as relações de vizinhança sofreram modificações é gerar os mapas várias vezes e assim verificar se ocorrem mudanças nas relações de vizinhanças. Para







c)




d)



e)



f)



g)

## CONCLUSÃO

A rede utilizada no tratamento dos dados de soja foi capaz de diferenciar as amostras oriundas de L das de PG com base nos valores de concentrações de componentes inorgânicos. Dentre todas as variáveis utilizadas destacam-se o Ca e o Zn, pois, estas foram as que mais contribuíram para a classificação. Ainda foi possível verificar, com exceção do B, que existe uma relação entre a concentração dos minerais no solo, com a concentração dos mesmos na soja, sendo que, de forma geral as amostras de soja plantadas em Londrina foram as que possuíram maior concentração de minerais. No entanto as variáveis utilizadas não foram suficientes para classificar as amostras quanto sua especificidade de transgenia.

Segundo a rede neural utilizada na análise dos dados de café não foi possível diferenciar as amostras, 172 no total, em relação a região de origem. Das 16 cidades estudadas 6 delas, sendo da região A Jesuítas (**b**) e São Jorge do Patrocínio (**c**), da região B Nova Esperança (**f**) e Uraí (**i**) e da região C Carlópolis (**m**) e Jacarezinho (**n**), não puderam ser agrupadas, sendo assim foram retiradas do banco de dados. No novo tratamento, composto por 96 amostras, novamente não foi possível separar adequadamente as amostras em relação a região de origem. Foi observado a formação de 6 grupos distintos; o primeiro formado pelas cidades de Jundiaí do Sul (**g**), Guapirama (**k**), Londrina (**h**) e Joaquim Távora (**l**); o segundo formado pelas cidades de Abatiá (**o**) e Conselheiro Mairinck (**p**) e os outros quatro grupos, cada um formado por uma cidade, sendo elas Francisco Alves (**a**), Brasilândia do Sul (**d**), Iporã (**e**) e Santa Mariana (**j**). Ao retirar as variáveis K, Mg e Mn do banco de dados, uma nova análise da rede mostrou não haver alteração no agrupamento das amostras. Porém, as relações de vizinhança não permaneceram as mesmas. Demonstrando que as variáveis retiradas do treinamento podem não contribuir muito na formação dos grupos mas, são importantes para a classificação de relação entre os grupos distintos.

Portanto mesmo não seguindo a forma que as amostras foram divididas em regiões foi possível o reconhecimento de padrão de 10 cidades das 16 estudadas, utilizando 10 concentrações de componentes inorgânicos.

## REFERÊNCIAS

AOAC. Association of Official Analytical Chemists, Official methods of analysis of the Association of Official Analytical Chemists. Washington, DC; 1990.

ANDROCIOLO FILHO, A. LIMA, F. B.; TRENTO, E. J.; CARNEIRO FILHO, F.; CARAMORI, P. H.; SCHOLZ, M. B. S. Caracterização da qualidade de bebida dos cafés produzidos em diversas regiões do Paraná. In: SIMPÓSIO DA PESQUISA DOS CAFÉS DO BRASIL, 3., 2003, Porto Seguro. Brasília: Embrapa Café, 2003, p.256-257.

AZEVEDO, F. M.; BRASIL, L. M. e OLIVEIRA, R. C. L. **Redes Neurais com Aplicações em Controle e em Sistemas Especialistas**. Florianópolis: Bookstore, 2000, 401p.

BODT, E.; COTTRELL, M.; VERLEYSEN, M. Statistical tools to assess the reliability of self-organizing maps. **Neural Networks**, v.15, p.967-978, 2002.

BOGER, Z. Selection of quasi-optimal inputs in chemometrics modeling by artificial neural network analysis. **Analytica Chimica Acta**, v.490, p.31-40, 2003.

BOISHEBERT, V.; GIRAUDEL, J. L.; MONTURY, M. Characterization of strawberry varieties by SPME-CG-MS and Kohonen self-organizing map. **Chemometrics and Intelligent Laboratory Systems**, v.80, p.13-23, 2006.

BONA, E. Integração de redes neurais artificiais ao nariz eletrônico avaliação aromática de café solúvel. 2008. Tese (Doutorado em Engenharia de Alimentos) – Universidade Estadual de Londrina. 2008.

BONA, E.; SILVA, R. S. S. F.; BORSATO, D.; BASSOLI, D. G. Self-organizing maps as a chemometric toll for aromatic pattern recognition of soluble coffe. **ACTA Scientiarum Technology**, v.34, n.1, p.111-119, 2012.

BRAGA, A. P.; CARVALHO, A. C. P. L. F. e LUDERMIR, T. B. **Redes Neurais Artificiais: Teoria e Aplicações**. Rio de Janeiro: LTC, 2000, 262p.

CALADO, V.; MONTGOMERY, D. C. **Planejamento de experimentos usando o Statística**. Rio de Janeiro: E-pappers, 2003, 260p.

CORNEY D. Food bytes: intelligent systems in food industry. **British Food Journal**, v.104, n.10, p.787-805, 2002.

DALL'AGNOL, A., ROESSING, A. C., LAZZAROTTO, J. J.; HIRAKURI, M. H. OLIVEIRA, A. B. O complexo agroindustrial da soja brasileira. **Circular Técnica**, v.1, p, 2007.

DEISINGH, A. K.; STONE, D. C.; THOMPSON, M. Applications of eletronic noses and tongues in food analysis. **International Journal of Food Science and Technology**, v.39, n. 6, p.587-604, jun. 2004.

DIN - Departamento de informática – **Uma Introdução a Redes Neurais Artificiais** – Universidade estadual de Maringá: [www.din.uem.br/ia/neurais/](http://www.din.uem.br/ia/neurais/). Acesso em: 12 de fevereiro de 2013.

FERRARI, R. A.; OLIVEIRA, V. S.; SCABIO, A. Biodiesel de soja – taxa de conversão em ésteres etílicos, caracterização físico química e consumo em gerador de energia. **Química Nova**, v.28, n.1, p.19-23, 2005.

FONSECA, A.M.; BISCAYA, J.L.; AIRES DE SOUZA, J.; LOBO, A. M. Geographical classification of crude oils by Kohonen self-organizing maps. **Analytica Chimica Acta**, v.556, n. 2, p. 374–382, jan. 2006.

GROSCH, W. Evaluation of the key odorants of foods by dilute experiments, aroma models and omission. **Chemical Senses**, v. 26, p.533-545, 2001.

HAMMOND, M. H.; RIEDEL, C. J.; ROSE-PEHRSSON, S. L.; WILLIAMS, F. W. Training set optimization methods for a probabilistic neural network. **Chemometrics and intelligent laboratory systems**, v.71, n. 1, p.73-78, abr. 2004.

HAYKIN, S. **Redes Neurais: Princípio e Práticas**. 2 ed. Porto Alegre: Bookman, 2001, 900p.

HUNTER, A.; KENNEDY, L.; HENRY, J. FERGUSOM, I. Application of neural networks and sensitivity analysis to improved prediction of trauma survival. **Computer Methods and Programs in Biomedicine**, v.62, n.1., p.11-19, mai. 2000.

KOHONEN, T. **Self Organizing Maps**. Series in Information Sciences, vol. 30, 2 nd, edition Springer – Verlag, Heidelberg, 1997.

KOLMAN, E.; MARGALLOT, M. Are artificial neural networks white boxes? **IEEE Transactions on neural networks**, v.16, n.4, p.844-852, jul. 2005.

KOVÁCS, Z. L. **Redes Neurais Artificiais: Fundamentos e Aplicações**. São Paulo: Editora Acadêmica, 1996, 163p.

LEE, J.; **Concise Inorganic Chemistry**. Londres: Chapman & Hall, 1966.

LEMES, M. R.; PINO J.; ARNALDO, D. A. Tabela periódica dos elementos químicos prevista por redes neurais artificiais de Kohonen. **Química Nova**, v.31, n.5, p.1141-1144, jul.2008.

LIAO, S. Expert system methodologies and applications – a decade review from 1995 to 2004. **Expert Systems with Applications**, v.28, n.1, p.93-109, jan.2005.

LINDER, R.; POPPL, S. J. A new neural network approach classifies olfactory signals with high accuracy. **Food Quality and Preference**, v.14, n.5, p.435-440, set. 2003.

MAEZTU, L.; SANZ, C.; ANDUEZA, S.; DE PENÃ, M.P.; BELLO, J. Characterization of espresso coffee aroma by static headspace gc-ms and sensory flavor profile. **Journal of Agricultural and Food Chemistry**, v. 49, n.11, p.5437-5444,2001.

- MARINI, F.; MAGRÌ, A. L.; BUCCI, R.; MAGRÌ, A. D. Use of different artificial neural networks to resolve binary blends of mono cultivar Italian olive oils. **Analytica Chimica Acta**, v.599, n. 2, p.232-240, set. 2007.
- MATIELLO, J. B., SANTINATO, R., MIGUEL, A. E., PAULINO, A. J., PAULINI, A. E., SEVANATO, S. G., BRANGANÇA, J. B. **A moderna cafeicultura de montanha**. Rio de Janeiro: PROCAFE-DFARA/RJ, 1994.
- MUKESH, D. Applications of Neural Computing for Process Chemists: Introduction to Neural Network. **Journal of Chemical Education**, v.73, n.5, p.431-433, mai. 1996.
- MAZZAFERA, P. Chemical composition of defective coffee beans. **Food Chemistry**, London, v. 64, n. 4, p. 547-554, 1999.
- NETO, J. M. M.; MOITA, G. C. Uma Introdução à Análise Exploratória de Dados Multivariados. **Química Nova**, v.21, n.4, p.467-469, out.1998.
- NOGUEIRA, F. T. P. **Integração dos mercados internos e externos de café**. 2005. 120 p. Tese (Doutorado em Economia Aplicada). Universidade Federal de Viçosa. Viçosa-MG, 2005.
- PAVAN, M. A.; BLOCH, M. D. M.; ZEMPULSK, H. C.; MIYAZAWA, M.; ZOCOLER, D. C. Manual de análises químicas de solo e controle da qualidade. Londrina: IAPAR, 1992. (Circular Técnica, n.76), p40.
- PITELLI, R. L. C. M.; FERRAUDO, A. S.; PITELLI, A. M. C. M.; PITELLI, R. A.; VELINE, E. D. Utilização de análise multivariada e redes neurais artificiais na determinação do comportamento de colonização de populações de macrófitas aquáticas no reservatório de Santana. **Planta Daninha**, v.27, n. 3, p.429-439, 2009.
- SPACINO, K.; CREMASCO, H.; ANGILELLI, K.; MESQUITA, M.; BORSATO, D. Using self-organizing maps as a chemometric tool for alcohol classification by distillery. **International Journal of Environment and Bioenergy**, v. 8, n. 1, p.1-11, out. 2013
- TOKUTAKA, H.; YOSHIHARA, K.; FUJIMURA, K.; OBU-CANN, K.; IWAMOTO, Application of self-organizing maps to chemical analysis. **Applied Surface Science**, v.144-145, p.59-63, abr. 1999.
- VERDINI, R. A.; ZORRILLA, S. E.; RUBIOLO, A. C.; NAKAI, S. Multivariate statistical methods for Port Salut Argentino cheese analysis based on ripening time conditions, and sampling sites. **Chemometrics and intelligent laboratory systems**, v.86, n. 1, p.60-67, mar. 2007.
- WARNER, B.; MISRA, M. Understanding Neural Networks as Statistical Tools. **The American Statistician**, v. 50, n. 4, p.284-293, few. 1996.

## **ANEXOS**

## ANEXO A

Tabela de concentrações dos componentes inorgânicos das amostras de soja utilizadas.

Cidade	Amostragem	K (g kg <sup>-1</sup> )	P (g kg <sup>-1</sup> )	Ca (g kg <sup>-1</sup> )	Mg (g kg <sup>-1</sup> )	S (g kg <sup>-1</sup> )	Zn (mg kg <sup>-1</sup> )	Mn (mg kg <sup>-1</sup> )	Fe (mg kg <sup>-1</sup> )	Cu (mg kg <sup>-1</sup> )	B (mg kg <sup>-1</sup> )
Londrina	LC	18,84	4,61	1,86	2,32	2,31	38,19	31,86	68,33	13,63	50,09
Londrina	LC	19,29	4,58	1,74	2,22	2,32	36,39	29,28	84,16	11,30	38,60
Londrina	LC	20,59	4,88	2,97	2,35	2,30	45,36	44,45	88,51	12,12	45,08
Londrina	LC	21,90	5,52	3,25	2,52	2,64	52,30	34,86	148,94	14,25	37,07
Londrina	LC	20,08	4,62	2,27	2,28	2,26	40,70	37,55	95,81	14,89	45,02
Londrina	LC	19,69	4,78	3,18	2,28	2,48	46,36	41,30	66,75	12,61	46,15
Londrina	LC	18,69	4,79	2,27	2,34	2,37	41,35	38,32	108,46	13,41	38,91
Londrina	LC	19,15	5,08	2,66	2,23	2,25	40,33	32,23	71,28	12,33	42,85
Londrina	LC	19,21	5,15	2,61	2,33	2,27	42,67	30,71	73,12	13,07	45,03
Londrina	LC	20,17	5,29	2,10	2,29	2,41	51,88	56,17	135,93	16,23	49,99
Londrina	LC	20,03	5,70	3,62	2,37	2,53	54,01	62,47	110,74	15,37	36,35
Londrina	LC	22,16	5,03	2,21	2,11	2,35	39,30	30,23	106,67	13,82	49,06
Londrina	LC	18,33	6,00	3,50	2,30	2,29	49,65	38,74	72,13	12,05	36,73
Londrina	LC	19,28	4,79	2,25	2,38	2,31	44,05	33,04	68,01	12,81	43,75
Londrina	LT	20,04	5,42	2,45	2,50	2,40	38,96	32,78	79,43	12,90	39,02
Londrina	LT	19,78	4,96	2,57	2,57	2,17	42,83	31,10	76,16	14,08	44,91
Londrina	LT	19,08	4,89	2,62	2,45	2,24	39,23	28,49	71,23	13,60	38,76
Londrina	LT	19,40	5,63	3,02	2,28	2,30	39,55	27,08	70,81	13,15	44,01
Londrina	LT	19,45	4,64	2,40	2,31	2,41	36,53	33,73	74,66	12,38	40,18
Londrina	LT	18,92	4,72	2,62	2,41	2,32	44,32	28,97	76,54	12,83	37,42
Ponta Grossa	PGC	18,64	4,54	1,41	2,42	2,26	30,40	19,27	96,77	12,83	42,43
Ponta Grossa	PGC	18,87	4,47	1,28	2,16	2,31	29,89	19,17	96,71	11,77	43,65
Ponta Grossa	PGC	20,25	4,72	2,05	2,28	2,38	33,26	20,74	96,08	11,96	39,70
Cidade	Amostragem	K	P	Ca	Mg	S	Zn	Mn	Fe	Cu	B

		(g kg <sup>-1</sup> )	(g kg <sup>-1</sup> )	(g kg <sup>-1</sup> )	(g kg <sup>-1</sup> )	(g kg <sup>-1</sup> )	(mg kg <sup>-1</sup> )	(mg kg <sup>-1</sup> )	(mg kg <sup>-1</sup> )	(mg kg <sup>-1</sup> )	(mg kg <sup>-1</sup> )
Ponta Grossa	PGC	18,09	4,43	1,94	2,25	2,34	31,61	22,02	94,15	11,81	38,40
Ponta Grossa	PGC	18,64	4,80	1,58	2,28	2,33	27,54	18,38	103,36	12,05	48,89
Ponta Grossa	PGC	20,09	4,87	2,00	2,29	2,35	31,99	19,59	84,53	12,43	35,22
Ponta Grossa	PGC	17,85	4,53	1,46	2,23	2,28	30,00	22,09	102,87	12,01	42,70
Ponta Grossa	PGC	18,18	4,60	1,56	2,29	2,31	29,48	22,91	117,25	10,84	42,40
Ponta Grossa	PGC	17,30	4,18	1,53	2,16	2,34	26,69	17,18	81,59	10,94	37,77
Ponta Grossa	PGC	18,03	4,38	1,40	2,10	2,35	26,04	18,21	112,41	11,92	44,08
Ponta Grossa	PGC	18,29	4,08	2,02	2,15	2,29	29,95	20,60	96,94	12,63	43,30
Ponta Grossa	PGC	20,09	4,78	1,53	1,95	2,36	32,50	18,86	97,04	13,02	39,21
Ponta Grossa	PGC	17,22	4,54	1,42	2,33	2,35	31,22	20,37	79,63	10,76	43,20
Ponta Grossa	PGC	18,40	4,62	1,43	2,47	2,34	27,85	19,22	88,95	11,81	46,58
Ponta Grossa	PGT	18,30	4,53	1,36	2,32	2,32	27,46	16,61	87,69	12,85	45,97
Ponta Grossa	PGT	17,33	4,13	1,39	2,23	2,26	27,56	17,27	90,50	11,15	49,41
Ponta Grossa	PGT	16,71	3,89	1,42	2,24	2,31	27,08	17,49	89,42	11,59	43,77
Ponta Grossa	PGT	16,45	4,02	1,13	2,07	2,31	28,87	18,65	76,60	11,31	37,29
Ponta Grossa	PGT	17,18	4,29	1,49	2,16	2,31	26,19	20,14	88,91	10,94	35,78
Ponta Grossa	PGT	17,52	4,53	1,69	2,41	2,32	31,75	19,52	160,41	10,76	38,55

## ANEXO B

Tabela de concentrações dos componentes inorgânicos das amostras de café utilizadas.

Região	Cidade	P (g kg <sup>-1</sup> )	K (g kg <sup>-1</sup> )	Ca (g kg <sup>-1</sup> )	Mg (g kg <sup>-1</sup> )	Cu (mg kg <sup>-1</sup> )	Zn (mg kg <sup>-1</sup> )	B (mg kg <sup>-1</sup> )	Mn (mg kg <sup>-1</sup> )	Fe (mg kg <sup>-1</sup> )	S (g kg <sup>-1</sup> )
A	a	1,84	20,40	1,42	2,20	16,60	5,80	12,95	20,10	93,77	1,69
A	a	1,89	22,70	1,31	2,00	19,00	6,30	16,50	16,58	27,50	1,56
A	a	2,06	19,20	1,33	2,16	19,30	6,90	23,00	17,06	27,50	1,67
A	a	1,82	19,20	1,42	1,84	17,40	5,30	24,10	19,30	23,96	1,41
A	a	1,90	19,20	1,43	2,05	17,10	7,20	22,36	19,80	30,50	1,55
A	a	1,87	19,20	1,46	1,97	15,50	7,10	22,06	22,80	24,20	1,49
A	a	1,55	20,40	1,20	1,95	14,50	5,20	15,60	15,50	26,30	1,39
A	a	1,63	21,50	1,26	1,97	14,90	6,60	21,40	17,50	27,07	1,44
A	a	1,91	18,10	1,29	2,17	17,60	7,40	20,80	18,20	32,10	1,59
A	b	1,51	18,10	1,33	1,79	15,40	6,10	8,20	27,60	22,40	1,44
A	b	1,60	18,10	1,37	1,86	16,60	8,90	28,60	28,60	22,68	1,49
A	b	1,54	18,10	1,40	1,90	16,50	8,40	31,70	31,87	26,95	1,49
A	c	1,46	19,20	1,54	1,79	15,40	10,30	41,70	41,70	30,30	1,59
A	c	1,55	18,10	1,36	1,67	14,77	9,50	28,50	28,46	26,80	1,50
A	c	1,66	18,10	1,60	1,76	15,30	10,70	29,15	29,15	50,30	1,58
A	c	1,58	20,40	1,46	1,81	15,76	13,20	33,40	33,40	25,80	1,51
A	c	1,65	18,10	1,86	1,83	15,10	14,30	35,76	35,76	28,95	1,59
A	c	1,78	17,00	1,78	1,82	14,70	15,20	27,89	27,89	30,70	1,58
A	c	1,75	18,10	1,31	1,93	14,70	10,77	16,30	38,67	38,90	1,57
A	c	1,94	18,10	1,47	2,00	15,60	11,50	21,08	36,40	34,87	1,73
A	c	1,75	17,00	1,32	1,81	15,50	7,20	15,20	33,10	30,75	1,58
A	c	1,86	18,10	1,55	1,87	18,30	8,30	11,70	30,50	33,58	1,51
A	c	1,97	18,10	1,30	1,98	17,68	7,00	12,80	20,10	37,00	1,58
Região	Cidade	P (g kg <sup>-1</sup> )	K (g kg <sup>-1</sup> )	Ca (g kg <sup>-1</sup> )	Mg (g kg <sup>-1</sup> )	Cu (mg kg <sup>-1</sup> )	Zn (mg kg <sup>-1</sup> )	B (mg kg <sup>-1</sup> )	Mn (mg kg <sup>-1</sup> )	Fe (mg kg <sup>-1</sup> )	S (g kg <sup>-1</sup> )
A	c	2,00	18,10	1,35	1,88	17,95	7,80	11,40	30,40	32,99	1,48
A	c	2,18	19,20	1,46	2,44	18,08	8,60	13,00	22,70	30,98	1,72

A	c	1,99	19,20	1,39	2,19	17,68	13,40	13,20	25,80	29,80	1,64
A	c	2,22	19,20	1,28	2,19	17,68	8,10	11,26	24,80	25,60	1,68
A	c	2,05	19,20	1,34	2,21	16,80	6,80	12,80	29,66	34,25	1,63
A	c	2,23	19,20	1,20	2,38	16,50	7,30	13,20	24,26	30,90	1,68
A	d	1,69	19,20	1,30	2,11	16,95	5,40	8,20	26,57	29,30	1,73
A	d	1,86	18,10	1,44	2,24	17,15	7,00	8,80	35,57	28,78	1,72
A	d	1,79	19,20	1,62	2,22	18,80	10,77	9,10	30,40	33,67	1,81
A	d	1,10	9,50	0,80	1,25	12,10	4,80	5,90	16,90	17,40	0,98
A	d	0,93	9,50	0,73	1,16	11,30	4,20	5,60	15,67	16,08	0,88
A	d	1,78	19,20	1,36	2,20	18,30	8,40	9,00	26,60	32,40	1,74
A	d	1,87	18,10	1,27	2,25	18,50	6,60	9,30	32,30	36,70	1,75
A	d	1,78	19,20	1,64	2,26	18,70	8,10	10,20	35,10	30,00	1,74
A	d	1,73	18,10	1,41	2,21	18,68	6,70	8,70	30,30	29,50	1,78
A	d	1,78	18,10	1,22	2,17	19,10	9,20	9,40	27,30	33,10	1,68
A	e	2,37	18,10	1,46	2,23	18,70	6,30	19,00	19,60	39,90	1,73
A	e	2,38	17,00	1,19	2,22	17,80	6,20	16,60	22,50	29,10	1,72
A	e	2,50	18,10	1,38	2,29	19,30	7,10	19,85	26,80	34,30	1,79
B	f	1,59	17,00	1,35	2,10	10,90	11,20	10,10	16,80	24,50	1,42
B	f	1,67	17,00	1,63	2,02	13,90	6,10	10,00	18,80	25,69	1,40
B	f	1,81	18,10	1,29	2,09	12,30	7,40	17,50	16,90	31,20	1,47
B	f	1,61	18,10	1,77	2,15	13,40	13,00	13,40	17,88	28,88	1,50
B	f	1,71	18,10	1,28	2,00	12,50	8,30	12,40	22,26	23,00	1,43
B	f	1,55	18,10	1,25	2,15	13,75	6,70	11,88	49,20	24,87	1,45
B	f	1,92	19,20	1,37	1,85	17,00	6,80	22,00	25,60	20,98	1,43
B	f	1,84	19,20	1,46	2,01	14,30	6,90	17,30	17,30	23,38	1,48
Região	Cidade	P (g kg <sup>-1</sup> )	K (g kg <sup>-1</sup> )	Ca (g kg <sup>-1</sup> )	Mg (g kg <sup>-1</sup> )	Cu (mg kg <sup>-1</sup> )	Zn (mg kg <sup>-1</sup> )	B (mg kg <sup>-1</sup> )	Mn (mg kg <sup>-1</sup> )	Fe (mg kg <sup>-1</sup> )	S (g kg <sup>-1</sup> )
B	f	1,73	18,10	1,45	1,95	15,25	6,30	17,30	17,30	26,50	1,43
B	f	1,92	18,10	1,25	1,96	13,56	10,10	21,50	21,50	25,80	1,55
B	f	1,77	18,10	1,18	2,02	18,50	10,20	24,40	24,40	30,20	1,41
B	f	1,58	18,10	1,36	2,15	14,75	6,80	39,50	39,50	26,30	1,47

B	f	2,00	20,40	1,21	1,85	16,50	5,10	21,08	21,08	21,76	1,48
B	f	1,62	17,00	1,25	2,03	14,30	8,00	60,80	60,80	23,10	1,45
B	f	1,89	14,80	1,25	1,88	16,60	16,50	53,65	53,65	28,15	1,50
B	f	1,77	14,80	1,27	2,09	15,56	13,65	52,30	52,30	29,98	1,60
B	f	1,67	12,60	1,35	2,07	14,50	6,10	10,88	66,88	27,40	1,48
B	f	1,67	15,90	1,44	1,92	14,56	6,20	9,10	27,68	34,90	1,35
B	f	1,80	17,00	1,66	2,18	18,10	7,60	16,10	38,20	29,77	1,50
B	f	1,81	14,80	1,44	1,97	17,10	7,80	10,10	83,36	28,99	1,49
B	g	1,72	14,80	1,12	1,70	13,07	7,70	7,10	87,66	24,88	1,26
B	g	1,56	14,80	0,99	1,57	12,40	7,40	6,20	109,10	20,70	1,28
B	g	1,77	14,80	1,14	1,71	12,96	7,40	5,10	109,20	20,65	1,34
B	g	1,53	14,80	1,09	2,05	12,67	6,30	10,60	38,40	26,59	1,42
B	g	1,50	17,00	0,85	1,67	13,20	5,90	7,50	37,69	21,77	1,25
B	g	1,49	13,70	0,82	1,68	12,90	5,90	6,00	32,80	25,20	1,27
B	h	1,43	14,80	1,02	2,19	13,50	6,70	7,90	22,30	29,60	1,40
B	h	1,49	13,00	1,06	2,26	13,30	6,20	8,30	20,05	31,60	1,37
B	h	1,56	12,60	1,35	2,07	13,58	8,30	9,30	27,80	29,30	1,43
B	h	1,46	13,70	1,13	2,04	12,80	5,60	7,40	28,60	29,80	1,38
B	h	1,41	11,60	1,30	2,00	13,50	7,10	8,20	26,96	28,00	1,42
B	h	1,55	13,70	1,46	2,02	13,80	9,00	11,30	38,08	27,55	1,48
B	h	1,62	14,80	1,13	2,08	13,98	8,70	11,60	38,40	27,70	1,46
B	h	1,51	14,80	1,06	1,94	12,90	7,40	6,30	27,40	25,97	1,34
Região	Cidade	P (g kg <sup>-1</sup> )	K (g kg <sup>-1</sup> )	Ca (g kg <sup>-1</sup> )	Mg (g kg <sup>-1</sup> )	Cu (mg kg <sup>-1</sup> )	Zn (mg kg <sup>-1</sup> )	B (mg kg <sup>-1</sup> )	Mn (mg kg <sup>-1</sup> )	Fe (mg kg <sup>-1</sup> )	S (g kg <sup>-1</sup> )
B	h	1,66	14,80	1,25	1,99	14,30	9,30	8,00	30,10	28,80	1,47
B	h	1,43	17,00	0,99	1,78	13,58	7,70	8,00	27,98	28,10	1,31
B	h	1,44	15,90	0,89	1,96	15,40	9,70	9,50	51,35	43,20	1,42
B	h	1,43	13,70	0,91	1,90	15,50	8,60	8,60	58,99	31,75	1,43
B	h	1,47	10,50	1,08	1,96	13,20	7,70	8,00	32,85	27,70	1,34
B	h	1,52	12,60	1,02	1,77	13,58	8,00	8,30	22,80	25,69	1,34
B	h	1,52	14,80	1,03	1,75	11,50	7,70	7,30	16,30	24,40	1,29

B	h	1,52	19,20	1,37	1,79	12,60	7,40	8,40	17,58	22,80	1,38
B	h	1,57	19,20	1,06	1,73	12,20	6,90	7,70	15,96	21,50	1,28
B	h	1,41	15,90	0,88	1,69	10,20	11,28	6,50	14,98	20,09	1,17
B	h	1,44	15,90	0,88	1,80	11,30	6,80	7,10	16,89	20,77	1,23
B	h	1,41	15,90	0,93	1,73	10,96	7,50	6,60	20,50	21,90	1,18
B	i	2,04	18,10	1,23	2,06	20,40	4,90	21,30	22,85	28,70	1,66
B	i	2,15	17,00	1,24	2,13	21,40	5,90	25,60	25,10	32,50	1,78
B	i	2,03	18,10	1,59	2,15	22,30	7,30	21,66	22,50	37,85	1,77
B	i	1,84	17,00	1,20	1,92	20,50	6,00	11,10	32,18	33,50	1,42
B	i	1,82	17,00	1,07	2,00	19,30	6,20	12,97	33,40	30,69	1,41
B	i	1,90	17,00	1,14	1,98	20,07	6,30	12,20	33,47	33,20	1,45
B	i	1,99	18,10	0,97	1,87	19,50	7,90	11,40	28,00	27,45	1,51
B	i	1,78	17,00	1,41	1,95	19,20	6,70	11,50	29,30	30,98	1,53
B	i	1,80	17,00	1,47	1,71	14,70	7,80	13,50	31,60	32,07	1,49
B	i	1,82	18,10	1,63	1,92	14,30	7,60	10,90	63,10	30,40	1,69
B	i	1,77	18,10	1,71	2,04	15,50	7,60	10,20	70,20	34,59	1,78
B	j	1,85	15,90	1,61	1,85	15,00	8,10	12,07	58,80	40,80	1,71
B	j	2,05	15,90	1,90	1,96	15,30	8,80	13,30	64,10	40,40	1,78
B	j	2,09	17,00	2,19	1,87	15,20	8,80	15,50	45,10	41,00	1,79
Região	Cidade	P (g kg <sup>-1</sup> )	K (g kg <sup>-1</sup> )	Ca (g kg <sup>-1</sup> )	Mg (g kg <sup>-1</sup> )	Cu (mg kg <sup>-1</sup> )	Zn (mg kg <sup>-1</sup> )	B (mg kg <sup>-1</sup> )	Mn (mg kg <sup>-1</sup> )	Fe (mg kg <sup>-1</sup> )	S (g kg <sup>-1</sup> )
B	j	2,28	18,10	1,61	1,72	16,09	9,80	29,40	25,30	39,20	1,71
B	j	2,14	17,00	1,79	1,73	16,75	9,60	19,10	31,07	35,99	1,69
B	j	2,12	15,90	1,95	1,69	16,00	11,87	19,60	38,55	45,15	1,71
B	j	2,35	17,00	2,05	1,86	16,98	10,86	14,96	38,09	42,36	1,77
B	j	2,32	17,00	2,15	1,83	16,83	11,87	13,40	34,30	52,60	1,81
B	j	2,34	17,00	2,13	1,87	16,57	11,40	16,90	37,50	43,96	1,78
B	j	2,38	15,90	2,37	1,73	17,20	12,20	22,20	42,40	47,60	1,81
B	j	2,65	17,00	3,00	1,83	19,50	19,50	16,86	43,50	49,20	2,07
B	j	2,82	17,00	3,10	2,13	22,08	22,08	16,50	47,97	56,80	2,11
C	k	1,75	17,00	1,54	2,02	15,40	6,40	8,20	27,00	43,78	1,53

C	k	1,78	15,90	1,87	2,03	14,90	6,40	9,20	28,30	30,40	1,53
C	k	1,74	17,00	1,37	1,99	14,58	7,20	8,20	31,40	27,44	1,49
C	k	1,76	17,00	1,60	2,25	16,10	5,60	8,30	16,00	27,10	1,48
C	k	1,86	17,00	1,29	2,00	14,65	6,40	7,50	27,40	29,77	1,46
C	k	1,60	17,00	1,25	1,94	13,30	5,60	7,40	25,68	36,88	1,45
C	k	1,64	18,10	0,85	1,91	15,20	5,80	9,10	20,80	31,10	1,44
C	k	1,64	18,10	1,07	1,75	15,78	5,10	8,80	23,95	25,60	1,45
C	k	1,51	18,10	1,24	1,92	12,57	5,80	6,60	30,30	23,40	1,45
C	k	1,55	18,10	1,63	1,88	13,80	4,80	8,10	31,80	31,98	1,47
C	l	1,57	18,10	1,01	1,79	14,00	8,20	9,50	23,70	33,30	1,40
C	l	1,68	17,00	1,10	1,89	14,30	7,30	7,80	23,07	35,90	1,44
C	l	1,59	15,90	1,12	1,82	12,85	6,40	8,70	28,86	31,10	1,38
C	l	1,48	17,00	0,91	1,89	13,80	7,20	10,40	19,38	29,40	1,39
C	l	1,64	17,00	1,03	1,92	13,89	5,40	7,80	26,50	25,00	1,37
C	l	1,58	18,10	0,99	1,87	15,07	7,70	9,70	19,20	22,10	1,30
C	l	1,55	18,10	0,85	1,86	11,90	8,20	8,50	28,00	20,20	1,39
Região	Cidade	P (g kg <sup>-1</sup> )	K (g kg <sup>-1</sup> )	Ca (g kg <sup>-1</sup> )	Mg (g kg <sup>-1</sup> )	Cu (mg kg <sup>-1</sup> )	Zn (mg kg <sup>-1</sup> )	B (mg kg <sup>-1</sup> )	Mn (mg kg <sup>-1</sup> )	Fe (mg kg <sup>-1</sup> )	S (g kg <sup>-1</sup> )
C	l	1,51	19,20	1,05	1,95	12,40	8,60	9,50	26,70	21,20	1,44
C	l	1,58	19,20	0,95	1,90	12,50	8,90	8,10	31,20	24,20	1,49
C	m	1,70	19,20	1,51	1,75	13,89	10,17	11,87	23,30	23,80	1,42
C	m	1,73	18,10	1,50	1,82	15,10	11,90	11,68	25,95	48,40	1,49
C	m	1,69	18,10	1,36	1,77	15,10	5,10	7,70	65,00	23,90	1,40
C	m	1,65	17,00	1,72	1,92	16,00	13,00	16,00	34,76	35,88	1,63
C	m	1,64	18,10	1,25	1,86	13,50	9,00	12,10	47,15	33,00	1,50
C	m	1,71	18,10	0,98	1,87	12,20	8,90	12,60	35,20	31,50	1,47
C	m	1,83	18,10	1,17	1,89	15,20	8,60	13,80	34,08	29,30	1,47
C	n	1,49	18,10	1,32	1,76	13,06	4,70	8,70	20,46	21,80	1,33
C	n	1,46	17,00	1,59	1,79	14,00	7,80	9,80	20,26	47,15	1,42
C	n	1,37	18,10	1,16	1,70	13,50	4,50	8,00	19,30	26,37	1,31
C	n	1,51	18,10	1,12	1,65	16,10	5,30	11,20	45,97	23,10	1,39

C	n	1,53	17,00	1,13	1,62	17,50	7,20	11,50	48,37	24,50	1,37
C	n	1,60	18,10	1,52	1,86	18,20	7,60	12,50	39,97	29,20	1,49
C	n	1,61	18,10	1,13	1,78	14,90	6,10	11,00	54,20	21,50	1,37
C	n	1,67	18,10	1,13	1,79	15,56	6,60	11,40	59,20	20,90	1,47
C	n	1,67	18,10	1,49	1,75	16,10	13,10	20,00	35,57	34,18	1,59
C	n	1,54	18,10	1,40	2,02	13,60	7,80	15,35	24,90	26,30	1,40
C	n	1,51	18,10	1,75	2,09	15,50	6,30	18,50	25,58	31,60	1,48
C	n	1,51	18,10	2,09	2,04	17,50	7,90	13,67	22,60	38,40	1,51
C	n	1,48	18,10	1,18	1,90	15,20	10,40	15,50	19,10	26,67	1,46
C	n	1,57	18,10	1,48	1,98	17,40	15,60	18,00	22,20	30,00	1,57
C	n	1,53	18,10	0,84	1,85	13,60	11,10	15,90	19,60	42,20	1,39
C	n	1,46	19,20	0,86	1,98	13,75	9,30	14,70	21,70	24,77	1,38
C	n	1,44	19,20	0,93	1,86	12,40	11,40	15,40	25,10	23,90	1,32
Região	Cidade	P (g kg <sup>-1</sup> )	K (g kg <sup>-1</sup> )	Ca (g kg <sup>-1</sup> )	Mg (g kg <sup>-1</sup> )	Cu (mg kg <sup>-1</sup> )	Zn (mg kg <sup>-1</sup> )	B (mg kg <sup>-1</sup> )	Mn (mg kg <sup>-1</sup> )	Fe (mg kg <sup>-1</sup> )	S (g kg <sup>-1</sup> )
C	n	1,44	18,10	1,17	1,89	12,90	27,60	10,40	19,86	46,30	1,34
C	o	2,71	19,20	2,67	1,96	17,75	17,75	12,40	44,10	50,40	2,08
C	o	2,67	19,20	2,40	1,87	18,20	18,20	12,70	49,20	69,40	2,08
C	o	2,79	19,20	2,58	1,64	17,50	17,50	13,00	43,97	76,96	2,09
C	o	3,07	19,20	2,59	2,11	18,70	18,70	13,07	68,40	66,50	2,27
C	o	3,01	18,10	2,65	1,99	18,30	18,30	12,70	48,55	54,78	2,15
C	o	2,63	18,10	2,43	2,15	17,80	17,80	12,59	61,15	54,65	2,36
C	o	2,74	17,00	2,63	2,26	17,60	15,66	13,20	56,80	97,50	2,38
C	o	2,73	15,90	2,71	2,27	18,60	14,90	12,30	50,76	57,20	2,45
C	o	2,77	17,00	2,75	2,19	18,50	14,10	12,20	56,70	54,85	2,34
C	o	2,76	15,90	3,02	2,29	18,58	16,40	12,70	58,60	53,05	2,38
C	o	2,95	17,00	2,83	2,23	18,99	17,40	12,30	57,56	69,85	2,39
C	p	2,73	15,90	2,61	2,29	17,90	13,10	14,00	43,10	104,20	2,28
C	p	2,91	18,10	3,37	2,49	20,50	19,95	14,90	37,50	65,00	2,44
C	p	3,05	17,00	3,31	2,41	18,90	16,67	13,00	37,90	60,50	2,44
C	p	2,74	13,70	3,06	2,35	19,10	18,90	15,80	56,87	71,05	2,35

---

C	p	2,80	15,90	4,09	2,42	20,40	16,90	16,90	65,65	70,50	2,55
C	p	1,34	12,60	1,06	1,78	14,20	6,70	8,00	27,88	28,86	1,39

---

## ANEXO C

Tabela de valores de máximo, mínimo, média e desvio padrão para os dados de café em relação às cidades de origem, sem levar em consideração as cidades, b, c, f, i, m e n.

Amostras	Parâmetro	P (g kg <sup>-1</sup> )	K (g kg <sup>-1</sup> )	Ca (g kg <sup>-1</sup> )	Mg (g kg <sup>-1</sup> )	Cu (mg kg <sup>-1</sup> )	Zn (mg kg <sup>-1</sup> )	B (mg kg <sup>-1</sup> )	Mn (mg kg <sup>-1</sup> )	Fe (mg kg <sup>-1</sup> )	S (g kg <sup>-1</sup> )
Cidade <b>a</b>	Média	1,83	19,99	1,35	2,03	16,88	6,42	19,86	18,54	34,77	1,53
	Desvio Padrão	0,15	1,42	0,09	0,12	1,69	0,82	3,86	2,21	22,28	0,11
	Mínimo	1,55	18,10	1,20	1,84	14,50	5,20	12,95	15,50	23,96	1,39
	Máximo	2,06	22,70	1,46	2,20	19,30	7,40	24,10	22,80	93,77	1,69
Cidade <b>d</b>	Média	1,63	16,82	1,28	2,01	16,96	7,12	8,42	27,67	28,69	1,58
	Desvio Padrão	0,33	3,89	0,30	0,43	2,86	2,04	1,50	6,80	6,76	0,35
	Mínimo	0,93	9,50	0,73	1,16	11,30	4,20	5,60	15,67	16,08	0,88
	Máximo	1,87	19,20	1,64	2,26	19,10	10,77	10,20	35,57	36,70	1,81
Cidade <b>e</b>	Média	2,42	17,73	1,34	2,25	18,60	6,53	18,48	22,97	34,43	1,75
	Desvio Padrão	0,07	0,64	0,14	0,04	0,75	0,49	1,69	3,62	5,40	0,04
	Mínimo	2,37	17,00	1,19	2,22	17,80	6,20	16,60	19,60	29,10	1,72
	Máximo	2,50	18,10	1,46	2,29	19,30	7,10	19,85	26,80	39,90	1,79
Cidade <b>g</b>	Média	1,60	14,98	1,00	1,73	12,87	6,77	7,08	69,14	23,30	1,30
	Desvio Padrão	0,12	1,08	0,14	0,16	0,29	0,82	1,92	36,88	2,57	0,07
	Mínimo	1,49	13,70	0,82	1,57	12,40	5,90	5,10	32,80	20,65	1,25
	Máximo	1,77	17,00	1,14	2,05	13,20	7,70	10,60	109,20	26,59	1,42
Amostras	Parâmetro	P (g kg <sup>-1</sup> )	K (g kg <sup>-1</sup> )	Ca (g kg <sup>-1</sup> )	Mg (g kg <sup>-1</sup> )	Cu (mg kg <sup>-1</sup> )	Zn (mg kg <sup>-1</sup> )	B (mg kg <sup>-1</sup> )	Mn (mg kg <sup>-1</sup> )	Fe (mg kg <sup>-1</sup> )	S (g kg <sup>-1</sup> )
Cidade <b>h</b>	Média	1,49	14,72	1,09	1,92	13,08	7,88	8,22	27,79	27,31	1,36

	Desvio Padrão	0,07	2,22	0,17	0,16	1,35	1,31	1,39	11,71	5,13	0,09
	Mínimo	1,41	10,50	0,88	1,69	10,20	5,60	6,30	14,98	20,09	1,17
	Máximo	1,66	19,20	1,46	2,26	15,50	11,28	11,60	58,99	43,20	1,48
Cidade <i>j</i>	Média	2,28	16,73	2,15	1,84	16,96	12,07	17,48	42,22	44,59	1,81
	Desvio Padrão	0,26	0,68	0,48	0,12	2,01	4,33	4,74	10,97	6,01	0,14
	Mínimo	1,85	15,90	1,61	1,69	15,00	8,10	12,07	25,30	35,99	1,69
	Máximo	2,82	18,10	3,10	2,13	22,08	22,08	29,40	64,10	56,80	2,11
Cidade <i>k</i>	Média	1,68	17,33	1,37	1,97	14,63	5,91	8,14	26,26	30,75	1,48
	Desvio Padrão	0,11	0,74	0,30	0,13	1,11	0,71	0,81	4,95	5,92	0,03
	Mínimo	1,51	15,90	0,85	1,75	12,57	4,80	6,60	16,00	23,40	1,44
	Máximo	1,86	18,10	1,87	2,25	16,10	7,20	9,20	31,80	43,78	1,53
Cidade <i>l</i>	Média	1,58	17,73	1,00	1,88	13,41	7,54	8,89	25,18	26,93	1,40
	Desvio Padrão	0,06	1,10	0,09	0,05	1,04	1,11	0,93	4,15	5,67	0,05
	Mínimo	1,48	15,90	0,85	1,79	11,90	5,40	7,80	19,20	20,20	1,30
	Máximo	1,68	19,20	1,12	1,95	15,07	8,90	10,40	31,20	35,90	1,49
Cidade <i>o</i>	Média	2,80	17,80	2,66	2,09	18,23	16,97	12,65	54,16	64,10	2,27
	Desvio Padrão	0,14	1,31	0,17	0,20	0,50	1,50	0,34	7,54	14,02	0,14
	Mínimo	2,63	15,90	2,40	1,64	17,50	14,10	12,20	43,97	50,40	2,08
	Máximo	3,07	19,20	3,02	2,29	18,99	18,70	13,20	68,40	97,50	2,45

Amostras	Parâmetro	P (g kg <sup>-1</sup> )	K (g kg <sup>-1</sup> )	Ca (g kg <sup>-1</sup> )	Mg (g kg <sup>-1</sup> )	Cu (mg kg <sup>-1</sup> )	Zn (mg kg <sup>-1</sup> )	B (mg kg <sup>-1</sup> )	Mn (mg kg <sup>-1</sup> )	Fe (mg kg <sup>-1</sup> )	S (g kg <sup>-1</sup> )
Cidade <i>p</i>	Média	2,60	15,53	2,92	2,29	18,50	15,37	13,77	44,82	66,69	2,24
	Desvio Padrão	0,63	2,05	1,03	0,26	2,32	4,85	3,13	13,93	24,14	0,43
	Mínimo	1,34	12,60	1,06	1,78	14,20	6,70	8,00	27,88	28,86	1,39

---

Máximo	3,05	18,10	4,09	2,49	20,50	19,95	16,90	65,65	104,20	2,55
--------	------	-------	------	------	-------	-------	-------	-------	--------	------