

UNIVERSIDADE ESTADUAL PAULISTA “JÚLIO DE MESQUITA FILHO”  
FACULDADE DE CIÊNCIAS AGRONÔMICAS  
CÂMPUS DE BOTUCATU

**PROCESSAMENTO DIGITAL DE IMAGENS PARA IDENTIFICAÇÃO  
DA SIGATOKA NEGRA EM BANANAIS UTILIZANDO ANÁLISE DE  
COMPONENTES PRINCIPAIS E REDES NEURAIS ARTIFICIAIS**

**SILVIA HELENA MODENESE GORLA DA SILVA**

Tese apresentada à Faculdade de Ciências  
Agronômicas da UNESP - Câmpus de Botucatu,  
para obtenção do título de Doutor em Agronomia,  
(Energia na Agricultura).

BOTUCATU – SP  
Dezembro – 2008

# **Livros Grátis**

<http://www.livrosgratis.com.br>

Milhares de livros grátis para download.

UNIVERSIDADE ESTADUAL PAULISTA “JÚLIO DE MESQUITA FILHO”  
FACULDADE DE CIÊNCIAS AGRONÔMICAS  
CÂMPUS DE BOTUCATU

**PROCESSAMENTO DIGITAL DE IMAGENS PARA IDENTIFICAÇÃO  
DA SIGATOKA NEGRA EM BANANAIS UTILIZANDO ANÁLISE DE  
COMPONENTES PRINCIPAIS E REDES NEURAIS ARTIFICIAIS**

**SILVIA HELENA MODENESE GORLA DA SILVA**

Orientador: Prof. Dr. Carlos Roberto Padovani

Tese apresentada à Faculdade de Ciências  
Agronômicas da UNESP - Câmpus de Botucatu,  
para obtenção do título de Doutor em Agronomia,  
(Energia na Agricultura).

BOTUCATU – SP  
Dezembro – 2008

FICHA CATALOGRÁFICA ELABORADA PELA SEÇÃO TÉCNICA DE AQUISIÇÃO E TRATAMENTO DA INFORMAÇÃO -  
SERVIÇO TÉCNICO DE BIBLIOTECA E DOCUMENTAÇÃO - UNESP - FCA  
LAGEADO - BOTUCATU (SP)

S586p Silva, Silvia Helena Modenese Gorla da, 1974-  
Processamento digital de imagens para identificação da sigatoka negra em  
bananais utilizando análise de componen- tes principais e redes neurais  
artificiais / Silvia Helena Modenese Gorla da Silva. - Botucatu : [s.n.],  
2008.

ix, 83 f. : il. color., gráfs., tabs.

Tese (Doutorado)-Universidade Estadual Paulista, Facul-  
dade de Ciências Agrônômicas, Botucatu, 2008

Orientador: Carlos Roberto Padovani

Inclui bibliografia

1. Análise multivariada. 2. Redes neurais artificiais. 3.  
Análise de componentes digitais. 4. Sigatoka negra. I. Pa-  
dovani, Carlos Roberto. II. Universidade Estadual Paulista  
"Júlio de Mesquita Filho" (Campus de Botucatu) Faculdade  
de Ciências Agrônômicas. III. Título.

**UNIVERSIDADE ESTADUAL PAULISTA "JÚLIO DE MESQUITA FILHO"**  
**FACULDADE DE CIÊNCIAS AGRONÔMICAS**  
**CAMPUS DE BOTUCATU**

**CERTIFICADO DE APROVAÇÃO**

TÍTULO: "PROCESSAMENTO DIGITAL DE IMAGENS PARA IDENTIFICAÇÃO  
DA SIGATOKA NEGRA EM BANANAIS UTILIZANDO ANÁLISE DE  
COMPONENTES PRINCIPAIS E REDES NEURAIS ARTIFICIAIS"

ALUNA: SILVIA HELENA MODENESE GORLA DA SILVA

ORIENTADOR: PROF. DR. CARLOS ROBERTO PADOVANI

Aprovado pela Comissão Examinadora

  
\_\_\_\_\_  
PROF. DR. CARLOS ROBERTO PADOVANI

  
\_\_\_\_\_  
PROF. DR. WILSON DA SILVA MORAES

  
\_\_\_\_\_  
PROF. DR. JOSÉ CARLOS MARTINEZ

  
\_\_\_\_\_  
PROFA. DRA. MARIE OSHIIWA

  
\_\_\_\_\_  
PROFA. DRA. SANDRA FIORELLI DE A. P. SIMEÃO

Data da Realização: 10 de dezembro de 2008

*Valeu a pena? Tudo vale a pena  
Se a alma não é pequena.  
Quem quer passar além do Bojador  
Tem que passar além da dor.  
Deus ao mar o perigo e o abismo deu,  
Mas nele é que espelhou o céu.*

*(Fernando Pessoa)*

## **DEDICATÓRIA**

A Deus, pela minha existência. Aos meus sogros, Zenaide e Lúcio, por significarem para mim meus segundos pais, ajudando-me e torcendo por mim, sempre. À minha mãe, Maria Isabel, por “tudo”, desde o meu nascimento até os dias atuais, exemplo de bondade. Ao meu pai, Marcilio, por ser “o meu alicerce”, pessoa em quem me inspiro na realização de todos os meus atos, exemplo de honestidade e conduta de vida. E a vocês, José Henrique e Ana Carolina, como vos digo: “amores da minha vida”, pelo compartilhamento das realizações e, em algumas vezes, de sofrimento, pela falta que muitas vezes minha ausência lhes causaram. Obrigada por vocês existirem! A ajuda e o amor de vocês foram imprescindíveis para a realização deste trabalho.

## **AGRADECIMENTOS**

Ao Prof. Dr. Sérgio Hugo Benez, pela indicação ao Dr. Carlos Roberto Padovani.

Ao Prof. Dr. Carlos Roberto Padovani, pela orientação, conselhos e exemplo de conduta acadêmica.

Ao Prof. Dr. Wilson da Silva Moraes, pela motivação do Tema do Doutorado e ajuda com conhecimentos em Fitopatologia.

Ao pesquisador Lúcio André de Castro Jorge, pela ajuda e dicas na área de Processamento Digital de Imagens.

Ao meu aluno de iniciação científica, Hugo do Nascimento Bendini, pela ajuda e disponibilidade.

A todos os meus familiares e amigos, por toda ajuda desprendida.

A todos os colegas da UNESP- Registro, pelo companheirismo.

À UNESP, pelos conhecimentos adquiridos e serviços oferecidos.

À FUNDUNESP, pelo apoio financeiro.

A “TODOS”, que, de uma maneira ou de outra, contribuíram para a realização deste trabalho.

## SUMÁRIO

	<b>Página</b>
LISTA DE FIGURAS .....	vii
LISTA DE QUADROS .....	viii
LISTA DE TABELAS .....	ix
RESUMO .....	1
SUMMARY .....	2
1 INTRODUÇÃO.....	03
2 REVISÃO DA LITERATURA .....	06
2.1 Aspectos Gerais da Sigatoka Negra.....	06
2.1.1 Ciclo da Sigatoka Negra.....	08
2.1.2 Monitoramento da Severidade da Sigatoka Negra .....	12
2.1.3 Controle da Sigatoka Negra.....	13
2.2 Processamento Digital de Imagens.....	16
2.2.1 Fases do Processamento Digital de Imagens.....	18
2.3 Redes Neurais Artificiais.....	19
2.3.1 Histórico das Redes Neurais Artificiais .....	20
2.3.2 Características Gerais das Redes Neurais Artificiais .....	22
2.4 Estatística Multivariada .....	27
2.4.1 Análise de Componentes Principais .....	29
2.5 Aplicações das técnicas utilizadas na Ciência Agrônômica.....	32
2.5.1 Processamento Digital de Imagens.....	33
2.5.2 Redes Neurais Artificiais.....	36
2.5.3 Estatística Multivariada .....	39
3 MATERIAL E MÉTODOS.....	43
4 RESULTADOS E DISCUSSÃO .....	47



5 CONCLUSÕES .....	57
6 REFERÊNCIAS BIBLIOGRÁFICAS .....	59
APÊNDICE – 1 .....	70

**LISTA DE FIGURAS**

	<b>Página</b>
Figura 1. Sintomas típicos da Sigatoka Negra em folhas de bananeira Prata ( <i>Musa AAB</i> ).....	07
Figura 2. Estádios do desenvolvimento da Sigatoka Negra .....	10
Figura 3. Planilha eletrônica, em formato MS-Excel .....	13
Figura 4. Rede Neural Artificial <i>Multilayer Perceptron</i> típica .....	26
Figura 5. Diagrama das etapas desenvolvidas no trabalho.....	46
Figura 6. Segmentação da Imagem de uma amostra da classe Sadia.....	47
Figura 7. Rede Neural Multicamadas utilizada no treinamento dos padrões .....	49
Figura 8. Porcentagem de concordância ausente média dos conjuntos de teste com intervalo de confiança para as classes .....	55
Figura 9. Porcentagem de concordância ausente média dos conjuntos de teste com intervalo de confiança para ausência e presença da doença .....	56

**LISTA DE QUADROS****Página**

Quadro 1. Evolução dos estádios do desenvolvimento dos sintomas da Sigatoka Negra.....	10
Quadro 2. Matriz de confusão do resultado de classificação do experimento .....	53

**LISTA DE TABELAS****Página**

Tabela 1. Autovalores e porcentagens de variação explicada e acumulada em cada componente principal. ....	48
Tabela 2. Resultados da classificação dos conjuntos de teste. ....	50
Tabela 3. Distribuição das classificações segundo os testes. ....	53
Tabela 4. Frequência de concordância entre origem e classificação pelo modelo proposto... ..	54
Tabela 5. Teste de Diagnóstico do modelo proposto.....	54

## RESUMO

O presente trabalho investigou a utilização do processamento digital de imagens conjuntamente com a análise de componentes principais e redes neurais artificiais como ferramentas de apoio para uma melhor identificação dos estádios iniciais do desenvolvimento da Sigatoka Negra, em nível de campo, para que medidas de controle sejam adotadas mais rapidamente e, assim, reduzir danos e prejuízos causados pela doença na bananicultura. Foram coletadas imagens digitais de folhas de bananeiras infectadas com a Sigatoka Negra nos estádios 1, 2 e 3, sadia e com fitotoxidez por óleo. A seguir, extraíram-se histogramas dos componentes de imagens no sistema RGB (*Red, Green e Blue*) para 256 intensidades de cinza das amostras, totalizando 768 variáveis para cada amostra. Com a aplicação de uma técnica de seleção de atributos, a análise de componentes principais, conseguiu-se reduzir as variáveis de entrada de 768 para 11 variáveis canônicas, representado uma redução de 98,6%. Em seguida, considerando-se as variáveis canônicas, realizou-se a fase de classificação com o uso de redes neurais artificiais. De maneira geral, as maiores frequências de acertos do modelo foram para as classes que mais interessam ao monitoramento da enfermidade, mostrando a robustez do classificador gerado, evidenciada pela baixa probabilidade de classificação incorreta (19%).

---

**Palavras-chave:** processamento digital de imagens, análise de componentes principais, redes neurais artificiais, Sigatoka Negra.

DIGITAL IMAGE PROCESSING FOR IDENTIFICATION OF BLACK SIGATOKA IN BANANA CROP USING PRINCIPAL COMPONENTS ANALYSIS AND ARTIFICIAL NEURAL NETWORKS IN THE. Botucatu, 2008. 83p. Tese de Doutorado (Doutorado em Agronomia/Energia na Agricultura) - Faculdade de Ciências Agronômicas, Universidade Estadual Paulista.

Author: SILVIA HELENA MODENESE GORLA DA SILVA

Adviser: CARLOS ROBERTO PADOVANI

## SUMMARY

This study investigated the application, specifically the digital processing of images, with main components analysis and artificial neural networks as tools to support for a better identification of the primaries stages of the Black Sigatoka, in field level, so that control measures are adopted more quickly and consequently it reduces injuries and damages caused by the disease in the banana crops. It were collected digital images of banana leaves infected with Black Sigatoka in stages 1, 2, and 3, healthy and with oil fitotoxicity. To proceed, histograms of the components of images were extracted in the system RGB (Red, Green and Blue) for 256 intensities shades of gray of the samples, totaling 768 variables for each sample. With the application of a technique of selection of attributes, the main components analysis, it was possible to reduce the variables of entrance of 768 for 11 canonical variables, represented a reduction of 98,6%. Therefore, being considered the canonical variables, it was accomplished the classification phase with the use of artificial neural networks. In a general way, the largest frequencies of successes of the model went to the classes that more they interest to the control of the diseases, showing the robustness of the generated classifier, evidenced by the low probability of wrong classification (19%).

---

**Keywords:** digital image processing, principal components analysis, ,artificial neural networks, Black Sigatoka.

## 1. INTRODUÇÃO

A bananicultura tem grande importância social no que diz respeito à geração de empregos, área cultivada e como fonte nutricional, pois seus frutos constituem alimento básico da população carente de diversos países e por ser consumida por todas as camadas sociais da população. A cultura da bananeira (*Musa spp.*) apresenta uma participação significativa na economia agrícola mundial. No ano de 2002, segundo dados da FAO (2005), foi a segunda fruta mais produzida no mundo, cultivada em 124 países do globo terrestre e ocupou uma área de 4.209.435 hectares correspondendo a 69.510.944 toneladas.

A importância da bananicultura para o agronegócio brasileiro é representada pelos registros de produção estimada em torno de 7 milhões de toneladas de banana em 2005, produzida numa área de 505 mil hectares com rendimento médio de 13,8 ton/ha (MAPA, 2007). Segundo dados do IBGE, no ano de 2001, a banana foi a segunda fruta mais produzida, ficando atrás somente da laranja. Apresentou uma área colhida de 510.313 ha, com uma produção de 6.177.293 toneladas de frutos, o que correspondeu a um volume de negócios superior a 1,8 bilhões de reais. O Estado de São Paulo é o principal produtor com 1.105.827 toneladas em 53.997 ha.

Na região do Vale do Ribeira, a cultura representa 1,7% do PIB estadual e 80% da receita, gerando mais de 30 mil empregos diretos e 45 mil indiretos. A maioria desses bananicultores (80%) é constituída por micro e pequenos produtores que produzem até 50 mil pés de banana que utilizam mão-de-obra familiar, enquanto o restante é constituído de médios e grandes produtores que produzem mais de 50 mil pés (GELMINI,

2004).

A Sigatoka Negra, causada pelo fungo *Mycosphaerella fijiensis* Morelet, é a mais severa e destrutiva doença da bananeira em todas as áreas produtoras do mundo, sendo responsável por perdas de produção superiores a 50%. A doença ocorre nas folhas, provocando estrias marrons e manchas negras necróticas que reduzem os tecidos fotossintetizantes e, conseqüentemente, os rendimentos brutos. O primeiro registro oficial da doença, em território brasileiro, deu-se no Estado do Amazonas no ano de 1998 e, em 2004, a doença foi constatada em bananais do Vale do Ribeira. Atualmente, encontra-se disseminada em todas as regiões produtoras do Estado de São Paulo.

O controle da doença tem sido feito por meio de aplicações alternadas de fungicidas sistêmicos e, ou protetores associadas às varias práticas culturais e variedades resistentes. No entanto, o intervalo e o número de aplicação de fungicidas são definidos com base no monitoramento semanal da severidade da doença em nível de campo. Entretanto, esse monitoramento é uma tarefa trabalhosa que requer uma estrutura mínima e envolve despesas contínuas com deslocamento e treinamento de técnicos capazes de identificar os estádios iniciais de desenvolvimento da doença. Os registros semanal dos estádios da doença e da emissão foliar são transferidos para planilhas apropriadas que calculam o estado de evolução atual da severidade e indicam a necessidade ou não da aplicação de fungicidas, cuja decisão é auxiliada pelos dados climáticos do local.

Esse método pode induzir a erros de observação, uma vez que é preciso identificar os estádios iniciais com auxílio de lentes de aumento (10 20 vezes), além de distinguir as lesões mortas (sobre efeitos de fungicidas) das lesões vivas, as lesões de Sigatoka Negra de Sigatoka Amarela, viroses e de fitotoxidez do óleo mineral, aplicado junto da calda fungicida, pois tarefas que necessitam de experiências e subjetividade do ser humano são altamente suscetíveis a erros.

Outras imprecisões de controle podem ser atribuídas às características geomorfológicas, cobertura vegetal, estradas de difícil acesso a bananais e às propriedades de pequeno porte, que tornam praticamente impossível realizar um diagnóstico preciso usando os métodos tradicionais.



No mundo globalizado, a agricultura intensiva depende, de forma crescente e irreversível, da utilização de insumos e tecnologias modernas, a fim de que os resultados sejam beneficiados cada vez mais com os avanços tecnológicos.

Uma alternativa interessante e atraente para lidar com este tipo de problema, trata-se do processamento digital de imagens associado com a análise multivariada de dados e redes neurais artificiais.

Neste sentido, pretendeu-se na presente pesquisa utilizar o processamento digital de imagens associado às técnicas multivariadas e redes neurais artificiais como ferramentas de apoio para melhor identificação dos estádios iniciais do desenvolvimento da Sigatoka Negra. Para tanto, as imagens de entrada utilizadas como padrões no experimento consistiram de pequenas amostras recortadas de folhas de bananeiras infectadas nos diversos estádios da doença e, posteriormente, digitalizadas. Dessa maneira, buscaram-se soluções, em âmbito de campo, para que medidas de controle sejam adotadas mais rapidamente e, assim, reduzir danos e prejuízos causados pela doença na bananicultura.

## 2. REVISÃO DA LITERATURA

### 2.1 Aspectos Gerais da Sigatoka Negra

A Sigatoka Negra é causada pelo fungo *Mycosphaerella fijiensis* Morelet (fase sexuada ou perfeita), cuja fase assexuada ou imperfeita denomina-se *Paracercospora fijiensis* (Morelet). A doença inicia-se pela infecção das folhas mais novas da bananeira e evolui para estrias marrons na face inferior e depois para manchas negras na superfície superior, durante o desenvolvimento destas folhas (MORAES et al. , 2006).

As manchas negras se tornam necróticas e coalescem rapidamente, exibindo uma queima generalizada do limbo foliar (Figura 1) que reduz os tecidos fotossintetizantes e, conseqüentemente, os rendimentos brutos. O fato de a bananeira não emitir mais folhas novas após o florescimento permite à doença tornar-se extremamente destrutiva em plantas que já emitiram cacho, especialmente nas variedades susceptíveis pertencentes ao subgrupo Prata, Cavendish(nanica e nanicão) e Terra. Os frutos de plantas severamente atacadas amadurecem precocemente no pé ou durante o transporte ou armazenamento ou não completam seu desenvolvimento (MORAES et al., 2006).



Figura 1. Sintomas típicos da Sigatoka Negra em folhas de bananeira Prata (*Musa AAB*), tendo na parte inferior as estrias (fase assexuada) e na superior as manchas negras e necroses (fase sexuada) do fungo *Mycosphaerella fijiensis*.

O fungo foi descrito pela primeira vez em 1963, nas Ilhas Fiji, distrito de Sigatoka, com denominação de raia Negra (MARÍN et al., 2003). O primeiro registro da doença no Brasil deu-se na fronteira com a Colômbia e o Peru, em 1998, quando foi introduzida pelos municípios de Tabatinga e Benjamin Constant, Estado do Amazonas, sendo rapidamente disseminada para toda a região Amazônica (PEREIRA et al., 1998; GASPAROTTO et al., 2006). Na região Sudeste, a doença foi constatada em junho de 2004, no município de Miracatu, Estado de São Paulo e, concomitantemente, em todos os municípios produtores de banana do Estado (FERRARI et al., 2005).

O Estado de São Paulo se destaca como o maior produtor de banana do Brasil, tendo, aproximadamente, 80% da produção concentrada em municípios do Vale do Ribeira. Esta região está localizada na porção sul do estado, possuindo clima tropical, úmido e bastante influenciada por massas de ar oceânicas vindas do Sul, que são barradas pelo relevo e se precipitam, causando um dos maiores índices pluviométrico do país. Este clima mostra-se propício, tanto para o desenvolvimento das plantas de bananeiras, que atingem produtividade média de 22,5 ton/ha, como também do fungo, agente causal da Sigatoka Negra.

Segundo Gonçalves et al. (2006), a detecção da presença de Sigatoka Negra nos bananais do Vale do Ribeira trouxe enormes preocupações não apenas por se tratar da principal região produtora paulista como por ser a banana o principal produto da agropecuária numa região colocada entre os piores indicadores de desenvolvimento humano no contexto estadual.

A partir deste relato, as instituições de pesquisa, extensão, defesa e fomento, em parceria com a associação dos bananicultores, conscientes do problema social e econômico que a doença representa para a região, priorizam esforços para a implantação imediata do sistema de manejo integrado da doença, baseado nas metodologias já estabelecidas nas principais regiões produtoras do mundo. Para isso, partem para a conscientização dos bananicultores por meio da transferência dos conhecimentos e das tecnologias já disponíveis em eventos técnico-científicos, necessários para a convivência com doença, reduzir os custos de proteção e a contaminação ambiental (MORAES et al., 2006).

Um incremento de 50% no número de aplicações de fungicidas ao ano foi constatado nos estudos desenvolvidos por Moraes et al. (2006), durante o primeiro ano da doença no Vale do Ribeira. De no máximo seis aplicações de fungicidas necessárias para o controle da Sigatoka Amarela, nove foram requeridas para o combate da Sigatoka Negra na safra 2005/2006. Estes são alguns dos efeitos negativos enfrentados pelos produtores de banana da região, diante da dispersão espacial e temporal da doença.

Os gastos com aplicação de defensivos, estimados em 2004 em R\$0,75 mil por hectare/ano subiram para R\$ 1,12 mil com a presença da doença na região, que também enfrenta problemas com a Sigatoka Amarela. O salto no número de aplicações de defensivos no Vale do Ribeira está concentrado no período que vai de final de outubro a março, com o aumento da temperatura e precipitação, favoráveis ao desenvolvimento da doença e da planta (GONÇALVES et al., 2006).

### **2.1.1 Ciclo da Sigatoka Negra**

O ciclo da Sigatoka Negra envolve uma seqüência de processos ordenados que se iniciam na fase de *sobrevivência* do fungo, presente na parte morta ou seca da folha mais velha da planta, onde estão localizados os esporos sexuais (ascósporos em peritécios). Esses ascósporos são *disseminados* pela ação do vento até a folha mais nova da planta (folha “vela”) ou de outras plantas, quando se iniciam os processos de *infecção, colonização e reprodução* (MORAES et al., 2008).

A *sobrevivência* do fungo corresponde à fase mais importante para o manejo integrado da doença. Nesta fase ocorre o final de um ciclo do fungo e início de outro ciclo, sendo responsável pelos novos sítios de infecção. Planta severamente atacada pela Sigatoka Negra apresenta mais folhas secas (lesões maduras) e, conseqüentemente, mais unidades infectivas do fungo (ascósporos) são liberadas dos peritécios para desencadear as novas infecções.

As infecções começam pela extremidade direita e inferior da folha “vela”, durante os processos de desenvolvimento ou desenrolamento. Esta é a fase de maior vulnerabilidade da folha à infecção, pois o fungo penetra pelos estômatos localizados na parte inferior da folha “vela”, ao mesmo tempo em que esta folha se mantém, por algum tempo, perpendicular à direção do vento que carrega os ascósporos. Os ascósporos chegam à superfície inferior da folha “vela”, onde são aderidos, germinam (emitem um tubo germinativo) e penetram pelos estômatos, causando uma infecção localizada em torno de cada estômato. Este processo inclui um *período de incubação* que vai desde a chegada dos ascósporos até o aparecimento do primeiro sintoma, que pode variar de sete a quinze dias, dependendo das condições de umidade e temperatura.

O primeiro sintoma é caracterizado pela presença de um diminuto ponto circular de descoloração, localizado entre duas micro-nervuras paralelas. Este sintoma toma a cor marrom, podendo ser visualizado com lentes de aumento (10 a 20 vezes) na primeira ou segunda folha a partir da folha “vela”. Uma vez estabelecida a infecção, o fungo passa a colonizar os tecidos da folha infectada exibindo os sintomas subseqüentes, ao mesmo tempo em que semanalmente novas folhas são emitidas pela planta.

Durante o processo de colonização dos tecidos da folha infectada, surgem os sintomas típicos da doença, os quais evoluem de pequenos pontos circulares de cor marrom, passando a pequenos traços a estrias, podendo ser visualizado apenas na superfície inferior das folhas mais novas da planta. As estrias evoluem para manchas negras visualizadas na face superior da folha. Estas manchas negras coalescem rapidamente exibindo grandes manchas que originaram a denominação e a diferenciação da Sigatoka Negra com a Sigatoka Amarela. A presença de manchas negras indica a morte das células, paralisação do crescimento e início do amadurecimento da lesão (Quadro 1 e Figura 2).

Quadro 1. Evolução dos estádios do desenvolvimento dos sintomas da Sigatoka Negra, conforme FOURÉ (1988), modificados por MORAES et al. (2005a), para as condições do Vale do Ribeira, SP, Brasil.

Estádio	Descrição	Denominação	Localização
1	Ponto de despigmentação diminuto, que toma a forma circular, cor marrom, limitado entre duas nervuras paralelas;	Ponto	Superfície inferior da 1ª folha em diante
2	Os pontos muito próximos passam a ser visualizado na forma de traço, limitado entre duas nervuras paralelas e mantém a cor marrom;	Traço	Superfície inferior da 2ª folha em diante
3	Os traços muito próximos passam a ser visualizado na forma de estria, que ultrapassam as duas nervuras paralelas e mantém a cor marrom;	Estria	Superfície inferior da 3ª folha em diante
4	As estrias evoluem para manchas de cor marrom escura ou negra que assumem formato elíptico e bordos irregulares;	Mancha negra	Superfície superior da 3ª folha em diante.
5	A mancha negra apresenta halo amarelo;	Mancha com halo amarelo	
6	As manchas apresentam centro deprimido, necrosado e aspecto seco, assumindo a cor esbranquiçada ou cinza clara, que coalescem formando grandes áreas necrosadas com pontos pretos (peritécios) no centro.	Mancha com necrose	




Figura 2. Estádios de desenvolvimento dos sintomas da Sigatoka Negra: 1. Ponto; 2. Traço; 3. Estria; 4. Mancha negra; 5. Mancha negra com halo amarelo; e 6. Mancha necrótica. Fonte: Orozco-Santos (1998).

Os estádios iniciais 1 e 2 são visualizados inicialmente na extremidade direita e inferior da primeira e segunda folha, apenas com auxílio de lentes com aumento de 10 a 20 vezes. Somente a partir do estádio 3, é possível a visualização dos sintomas (estrias) a olho nu, na superfície inferior da terceira ou quarta folha. Em casos mais severos da doença, verifica-se um rápido coalescimento das manchas negras (estádio 6), impossibilitando o aparecimento do halo clorótico, característico do estádio 5. No estádio 6, é possível observar a presença de numerosos pontos pretos (peritécios ou pseudotécios), que correspondem aos corpos de frutificação da fase sexuada ou perfeita do fungo. Esse é considerado o estádio final da doença, onde se observa o coalescimento de todas as lesões, caracterizando uma queima generalizada das partes afetadas (lesões maduras) (MORAES et al., 2008).

O ciclo da Sigatoka Negra inclui duas fases bem definidas da reprodução do fungo *Mycosphaerella fijiensis*, uma assexuada (conídios) e outra sexuada (ascósporos). Tanto os conídios como os ascósporos apresentam importância nesta epidemia, sendo o primeiro disseminado a curtas distâncias e o segundo, a longas distâncias.

Primeiramente, os ascósporos chegam à superfície da folha vela, onde são aderidos, germinam e penetram, causando infecção localizada no estômato. Após a infecção, o micélio do fungo coloniza internamente os espaços intercelulares em torno dos estômatos e iniciam o processo de reprodução assexuada, produzindo a partir dos estômatos os conídios em conidióforos. Essas estruturas assexuadas do fungo são produzidas até o final do ciclo, mas com aumento gradativo a partir dos estádios iniciais de ponto, traço e estria e começam a diminuir nos estádios de mancha negra e mancha com necrose. A partir do estádio de mancha, tem-se início a fase sexual do fungo, com produção de espermiácias e espermatócitos, os quais darão origem aos esporos sexuais (ascósporos) que são produzidos dentro de corpos de frutificação denominados peritécios ou pseudotécios.

Apesar dos conídios serem produzidos nas lesões iniciais da doença e contribuírem para a epidemia, o período latente é definido pelo tempo necessário para o fungo produzir lesões necróticas com peritécios maduros com ascósporos, as quais são consideradas as principais fontes de inóculo do fungo. Assim, quanto menor o período latente maior é a severidade da doença e vice-versa.

A disseminação da doença, tanto a curtas como a longas distâncias, ocorre principalmente devido à ação da chuva e do vento, respectivamente. Porém, a utilização

de folhas infectadas colocadas nas embalagens para prevenir ferimentos, as caixas contaminadas e mudas infectadas provenientes de locais de ocorrência da doença contribuem a dispersão dos esporos do fungo para áreas livres da doença. Importante salientar que a principal fonte de inóculo do fungo corresponde às folhas velhas de plantas severamente atacadas de bananais abandonados ou não-tratados, razão pela qual devem ser erradicadas e sofrerem os devidos tratamentos fitossanitários ou desfolhas (MORAES et al., 2008).

### **2.1.2 Monitoramento da Severidade da Sigatoka Negra**

A severidade da Sigatoka Negra na cultura da banana depende das condições climáticas predominantes nas áreas de cultivo. Em regiões com predomínio de temperaturas e precipitações mais elevadas, a severidade tende a ser maior, assim como nos meses mais quentes e chuvosos. De outro lado, nos meses mais frios e menos chuvosos do ano, a severidade tende a ser menor. Essas são fortes evidências da influência dos fatores climáticos sobre a severidade da doença.

Assim sendo, um sistema de previsão bioclimático torna-se uma ferramenta indispensável para se conhecer a severidade da doença em diferentes áreas de produção de banana ou estações do ano e indicar o momento correto da aplicação de fungicidas, o intervalo de aplicação e o grupo químico dos fungicidas mais apropriados para cada época do ano (PÉREZ, 1996; PÉREZ, 2000a; PÉREZ, 2000b).

A estimativa biológica (monitoramento da severidade) da Sigatoka Negra na cultura tem sido realizada pelo método de Estado da Evolução (EE), baseada no sistema de pré-aviso biológico desenvolvido por Ganry e Meyer (1972) para avaliar a severidade da Sigatoka Amarela e, em 1988, foi adaptado por Fouré para estimar o Estado de Evolução (EE) da Sigatoka Negra. Este método considera o ritmo de emissão foliar semanal (REF) e os estádios precoces do desenvolvimento dos sintomas (1, 2 e 3) presentes na segunda (II), terceira (III) e quarta (IV) folha, a partir da “vela”, em dez plantas amostradas a cada 50 hectares. O estado da evolução da severidade é definido pela equação:  $EE = SEV * REFx$ ;





A Sigatoka Negra, além de ser muito mais agressiva e destrutiva, ataca as cultivares consideradas resistentes à Sigatoka Amarela, dificultando seu controle. O controle da doença tem por base a utilização de cultivares resistentes, manejo cultural e de fungicidas sistêmicos e protetores. Entretanto, a produção comercial de bananas só é possível se levar em conta um sistema de manejo integrado da Sigatoka Negra. Para isso, torna-se necessário o conhecimento geral sobre a doença por parte dos técnicos e bananicultores (OROZCO-SANTOS, 1998; MARIN ; ROMERO, 1992).

Nas áreas onde a doença ainda não ocorre deve-se praticar o princípio de exclusão, ou seja, evitar a introdução do patógeno. Uma medida quarentenária seria a proibição do trânsito de materiais vegetais contaminados ou infectados provenientes das áreas de ocorrência da doença (MAPA, 2007). Nos bananais onde a doença já ocorre, é recomendado o controle genético com o uso de variedades resistentes ou o controle químico com fungicidas.

A escolha do método adequado de controle deve considerar os aspectos econômicos (custos de proteção e mercado), sociais e ambientais. As práticas de manejo cultural consistem na eliminação dos bananais abandonados ou não-tratados, na drenagem dos solos encharcados, nutrição adequada das plantas com base em análises de solo e foliar, controle de plantas invasoras, desfolha sanitária, corte e cirurgia de folhas atacadas e eliminação de plantas severamente atacadas.

A Sigatoka Negra tem sido eficientemente controlada com sucessivas aplicações de fungicidas sistêmicos e, ou protetores. No entanto, as aplicações de fungicidas envolvem custos mais elevados devido ao uso de aeronaves, instalação permanente de pistas de decolagem, tanques misturadores e abastecedores, além do próprio custo da aplicação de fungicidas. O custo de proteção dos bananais recentemente atacados pela doença no Vale do Ribeira, SP, chegou a um aumento de 50% em relação aos custos com a Sigatoka Amarela (MORAES et al., 2006). Este custo elevado tornou-se impraticável para a maioria de pequenos produtores de banana, que são os mais afetados por essa importante doença.

As práticas culturais, aliadas ao controle químico, correspondem a um dos componentes mais importantes no combate à Sigatoka Negra, uma vez que reduzem consideravelmente a fonte de inóculo inicial e evitam as condições favoráveis ao desenvolvimento da doença. A desfolha ou cirurgia constitui uma ferramenta indispensável

para a redução da produção do inóculo, desde que seja seguida da amontoa destas folhas, a cada 15 metros, para evitar a dispersão dos esporos do fungo (OROZCO-SANTOS, 1998). Na Colômbia, as desfolhas são realizadas com periodicidade de quatro semanas na época seca e duas semanas na época chuvosa (MERCHÁN; CHAVARRIAGA, 1994). Da mesma forma, a eliminação dos bananais abandonados corresponde a uma medida que depende da conscientização de todos os bananicultores, já que constitui a principal fonte de inóculo para os bananais.

A convivência com a Sigatoka Negra na região sudeste, especialmente no Vale do Ribeira, tem sido facilitada em função da ocorrência de baixas temperaturas em boa parte do ano, principalmente, entre os meses de maio a outubro, quando predominam temperaturas médias mínimas inferiores a 18°C. Porém, no período compreendido entre os meses de novembro e abril há predomínio de temperaturas e precipitações mais elevadas, quando a doença tem-se mostrado muito mais severa. Neste período, deve o bananicultor intensificar as aplicações fungicidas com base no monitoramento semanal da doença e aplicar as práticas culturais, sob pena de perder a luta contra a mais severa doença da bananeira no momento (MORAES et al., 2006).

O constante desafio da bananicultura da região sudeste consiste na manutenção das áreas livres da Sigatoka Negra nos Estados do Espírito Santo, Rio de Janeiro e parte de Minas Gerais por meio da inspeção permanente dos bananais e do rigor na aplicação das legislações estabelecidas para cada estado. Além disso, os bananicultores devem redobrar os cuidados com seus bananais, adotando as tecnologias já disponíveis, como os tratamentos culturais e o controle fitossanitário, já dispensados para a Sigatoka Amarela.

Nos bananais do Estado de São Paulo, a doença já está estabelecida e erradicá-la será uma tarefa praticamente impossível. Resta ao produtor conviver com a doença adotando as tecnologias já disponíveis para a Sigatoka Negra e procurar fortalecer a organização dos produtores e da produção. As organizações devem, junto aos órgãos de Defesa Agropecuária estadual e federal, criar mecanismos legais para a erradicação dos bananais abandonados, que constituem a principal fonte de inóculo da doença. Do contrário, o aumento anual do inóculo e do número de pulverizações ao ano pode inviabilizar a atividade para a maioria de pequenos produtores da região (MORAES et al., 2006).

As aplicações contínuas de fungicidas para controle da doença devem seguir rigorosamente as recomendações do FRAC (*Fungicide resistance action Committee*), pois, os países da América Central já utilizam 48 a 52 pulverizações anuais de fungicidas protetores e 24 a 28 de fungicidas sistêmicos, enquanto no Brasil, especificamente no Vale do Ribeira, Estado de São Paulo, realizam-se até 6 aplicações ao ano para controle da Sigatoka Amarela e de 8 a 10 para a Sigatka Negra.

Neste cenário, as pesquisas seguem nas instituições estaduais, federais e empresas privadas na incessante tarefa do desenvolvimento de variedades resistentes e de novas moléculas de fungicidas para controle da doença. No Pólo Regional do Vale do Ribeira – APTA tem-se realizado, a cada dois meses, o curso de identificação, monitoramento e controle da Sigatoka Negra na cultura da banana, com o objetivo de transferir conhecimentos e tecnologias aos bananicultores de todas as regiões do país para a convivência com a doença. Nesses eventos, bananicultores, agrônomos e técnicos aprendem a técnica de monitoramento semanal da doença que auxilia na tomada de decisão do momento correto da aplicação de fungicidas e, assim, garantir a produção esperada, reduzir os custos da proteção e a contaminação ambiental.

## **2.2 Processamento Digital de Imagens**

Por Processamento Digital de Imagens, entende-se a manipulação de imagens por computador, com objetivos que vão desde melhorar o aspecto visual de uma imagem, até extrair informações úteis e relevantes.

O processamento de imagens e sinais pode ser aplicado em diversas áreas, tais como: medicina, cartografia, indústria, manufatura, gráfica, cosméticos e estética pessoal; e em diversos campos científicos e de pesquisas como astronomia, análises de minerais, mecânica de fluidos, análises radioativas, física de partículas e modelagem oceânica (NIBLACK, 1986).

Adicionalmente, o processamento de imagens tem encontrado grande aplicação na agricultura (CRUVINEL, 1992; CRUVINEL et al., 1996; MODENESE, 1998).

Segundo Gomes e Velho (1994), um sinal se manifesta a partir da variação de uma determinada grandeza física, a qual pode ser em relação ao espaço ou ao tempo. Uma imagem é definida como sendo um sinal e sua variação se dá na cor dos diversos pontos do plano. Um sinal (imagem) pode ser representado por um objeto matemático que estabeleça a variação da grandeza física. Nos modelos funcionais, um sinal é representado por uma função  $f: U \subset R^m \rightarrow R^n$ , ou seja, a grandeza física do sinal é representada por um vetor  $n$ -dimensional que varia em um espaço com  $m$  graus de liberdade. Chama-se *espaço de sinais* a um subespaço de funções  $\{f: U \subset R^m \rightarrow R^n\}$  com  $U$ ,  $m$  e  $n$  fixos. Portanto, um espaço de sinais é um espaço de funções, ou seja, naturalmente, um espaço vetorial em relação às operações matemáticas usuais.

No *modelo espacial*, dada uma função  $f: U \subset R^m \rightarrow R^n$ , o subconjunto  $U$  representa a região do espaço no qual varia a grandeza física. Por essa razão,  $U$  é chamado de *domínio do espaço*. A grandeza física é representada por um vetor  $R^n$  e a lei de definição da função  $f$  fornece as regras de variação da grandeza. A dimensão  $m$  do domínio determina a dimensão do sinal. No caso da imagem,  $U$  é um subconjunto do plano euclidiano  $R^2$  e a função  $f$  associa a cada ponto  $p$  do plano o vetor  $f(p)$  que fornece a informação de cor em  $p$ . Uma imagem pode ser analógica ou digital.

Uma imagem monocromática digital é uma matriz de números inteiros, cujos elementos são chamados de *pixels* (binários 0 ou 1 ou em níveis de cinza entre 0 e 255). Em uma imagem digital colorida no sistema RGB (do inglês *Red, Green e Blue*), pode-se considerar um pixel como um vetor de cor cujas componentes representam as intensidades de vermelho, verde e azul. Pode-se considerar que a imagem colorida é a composição de três imagens monocromáticas:

$$f(x,y) = f_r(x,y) + f_g(x,y) + f_b(x,y), \text{ onde}$$

$f_r(x,y)$ ,  $f_g(x,y)$  e  $f_b(x,y)$  são, respectivamente, as intensidades das componentes vermelha (r), verde (g) e azul (b) da imagem no plano  $(x,y)$ . As imagens  $f_r(x,y)$ ,  $f_g(x,y)$  e  $f_b(x,y)$  são denominadas, respectivamente, de *banda vermelha*, *banda verde* e *banda azul da imagem colorida*.

### **2.2.1 Fases do Processamento Digital de Imagens**

Basicamente, existem algumas fases a serem seguidas para que ocorra o processamento digital de imagens: aquisição da imagem, pré-processamento, segmentação e análise.

#### **Aquisição da Imagem**

Essa fase consiste na aquisição da imagem, propriamente dita, e conversão do formato analógico para o digital, se necessário.

#### **Pré-processamento**

Após a imagem ter sido digitalizada e armazenada, técnicas de *pré-processamento* podem ser utilizadas para melhorar a sua qualidade. Estas técnicas consistem na maior parte das vezes, na utilização de funções lineares e não-lineares visando o melhoramento de contraste, remoção de ruído, busca de regiões de interesse, codificação das informações para a sua transmissão, reamostragem dos pixels em uma nova escala, treinamento e extração de características de imagem para segmentação, entre outras. As técnicas de pré-processamento envolvem duas categorias principais que podem operar nos domínios espacial ou da frequência.

#### **Segmentação**

Segundo Nevatia (1986), a segmentação é a operação de separar os componentes de uma imagem em subconjuntos que correspondem a objetos ou regiões, cuja classificação tem por finalidade agrupar cada objeto em diferentes categorias. Os métodos clássicos de segmentação estão divididos em três grandes grupos: limiarização, segmentação por bordas e segmentação por regiões. Outras abordagens têm sido utilizadas, como o uso de redes neurais, algoritmos genéticos ou técnicas de análise multivariada de dados.

#### **Análise**

Uma vez segmentados os objetos de interesse e efetuados os processamentos básicos, a última etapa para completar o estudo pelo processamento de

imagens é a análise. Nessa fase, buscam-se extrair informações úteis e relevantes para cada aplicação desejada.

### 2.3 Redes Neurais Artificiais

O cérebro humano contém em torno de  $10^{11}$  neurônios, sua célula fundamental. Cada um desses neurônios processa e se comunica com milhares de outros continuamente e em paralelo. Os neurônios biológicos estão conectados uns aos outros por meio de conexões sinápticas (BRAGA et al., 2000).

As Redes Neurais Artificiais (RNA) apresentam características particulares, tais como: capacidade de aprender, generalizar, agrupar ou organizar dados; não linearidade; mapeamento entrada/saída; adaptabilidade; respostas com níveis de confiança; agregação de informação contextual; tolerância a falhas; uniformidade de análise e projeto; analogia neurobiológica (HAYKIN, 1999).

A estrutura individual dos nodos ou *neurônios* (unidades de processamento simples), a topologia de suas conexões e o comportamento conjunto destes nodos naturais formam a base para estudo das RNA. As Redes Neurais Artificiais são sistemas computacionais inspirados na estrutura, método de processamento e habilidade de aprendizado de um “cérebro biológico” (CYBENKO, 1996).

As RNA tentam reproduzir as funções das redes biológicas, buscando implementar seu comportamento físico. No momento, as redes artificiais se diferem bastante das redes biológicas. É importante, contudo, observar as similaridades entre elas, das quais se podem destacar (BRAGA et al., 2000):

o processamento básico da informação ocorre em diversos *neurônios*;

- a informação entre os neurônios é transmitida através das conexões ou sinapses;
- os neurônios estão interconectados gerando as redes neurais;

- o conhecimento é adquirido do ambiente por meio de um processo de *aprendizagem*, que é o principal responsável por adaptar os pesos das conexões entre neurônios.

Ao contrário das técnicas convencionais de computação, onde um programa de computador precisa ser desenvolvido para resolver um dado problema, redes neurais artificiais aprendem a solucionar problemas por aprendizado e experiência, como ocorre com os seres humanos.

As RNA constituem uma alternativa à utilização de técnicas estatísticas para a classificação e agrupamento de dados, podendo também ser utilizadas para encontrar correlações e agrupamentos naturais entre dados. Diferentemente de muitas das técnicas estatísticas utilizadas, para que as RNA sejam empregadas, não é necessário conhecer a distribuição probabilística dos dados.

### **2.3.1 Histórico das Redes Neurais Artificiais**

O início do estudo de redes neurais artificiais deu-se na primeira metade da década de 40 com um trabalho pioneiro de McCulloch e Pitts (1943). Segundo Haykin (1999), McCulloch foi um psiquiatra e neurocientista por treinamento, no qual passou cerca de 20 anos refletindo sobre a representação de um evento no sistema nervoso. Já Pitts foi matemático prodígio que se associou a McCulloch em 1942. Nesse trabalho, McCulloch e Pitts descrevem um cálculo lógico das redes neurais, de maneira a unificar os estudos da neurofisiologia e lógica matemática. Esse trabalho já demonstrou, claramente, a interface das ciências exatas e biológicas e com ele se deu o nascimento não dos estudos em RNA, mas, sobretudo, da Inteligência Artificial.

De acordo com Braga et al. (2000), o trabalho de McCulloch e Pitts se concentra muito mais em descrever um modelo artificial de um neurônio do que apresentar técnicas de aprendizado. Grande parte dos estudos em RNA se baseia em métodos de aprendizado para que os nodos possam ser capazes de executar uma determinada função.

Já o primeiro trabalho que apresentou de fato uma formulação explícita de uma regra de aprendizagem, deu-se no final da década de 40, em 1949, por



Donald Hebb (HEBB, 1949). Esse trabalho propôs o postulado de aprendizagem, que afirma que o aprendizado em nodos biológicos é baseado no reforço das ligações sinápticas entre nodos excitados.

No final dos anos 50 e início da década de 60, Rosenblatt (1962), com uma nova abordagem para o problema de reconhecimento de padrões e com seu novo modelo de rede neural, o *perceptron* demonstrou um método inovador do aprendizado supervisionado, o qual foi chamado de Teorema de Convergência do *Perceptron*. Esse *Perceptron* simples, somente é capaz de classificar padrões que sejam linearmente separáveis. Em 1960 também, Widrow e Hoff introduziram o algoritmo LMS (*Least Mean-Square*), usando-o para formular o *Adaline* (do inglês, *adaptive linear element*). O *Adaline* diferencia-se do *perceptron* no procedimento de aprendizagem (HAYKIN, 1999).

Em 1969, Minsky e Papert (1969) demonstraram matematicamente os limites impostos pelo *perceptron* de camada única, no que diz respeito a problemas que não são linearmente separáveis.

Segundo Braga et al. (2000), nos anos 70, o conexionismo ficou adormecido em grande parte ao trabalho de Minsky e Papert. Apesar de diversos pesquisadores continuarem a trabalhar na área, entre eles Igor Aleksander, Kunihiko Fukushima, Steven Grosberg e Teuvo Kohonen, um bom número de outros pesquisadores abandonou as pesquisas em RNA.

Os anos 80 destacaram-se como um período de ressurgimento para as pesquisas em RNA devido, em grande parte, às excelentes contribuições que as Redes apresentaram, tanto na teoria quanto em pesquisas experimentais.

Grossberg (1987) estabeleceu um novo princípio de auto-organização conhecido como teoria da ressonância adaptativa (*ART, Adaptive Resonance Theory*). Um grande impulso foi dado na área em 1982 por Hopfield ao utilizar a idéia de uma função de energia para formular um novo modo de se estender à computação executada por redes recorrentes com conexões sinápticas simétricas. Isso despertou nos físicos teóricos grande interesse pela modelagem neural. Também no ano de 1982, houve a publicação de Kohonen sobre os mapas auto-organizáveis. A partir de então, devido sobretudo a um contexto de grandes avanços tecnológicos, vários acontecimentos têm impulsionado cada vez mais a comunidade conexionista (HAYKIN, 1999).

Assim, as RNA fixaram-se como um campo de pesquisa em diferentes domínios do conhecimento e com aplicações nas mais diversas áreas, de maneira a crescer sempre.

### 2.3.2 Características Gerais das Redes Neurais Artificiais

As RNA são estruturas formadas por um grande número de unidades de processamento (que simulam os neurônios), bastante simplificadas e conectadas entre si. Essas conexões são implementadas por canais de comunicação que estão associados a um determinado peso. As unidades realizam operações apenas sobre seus dados locais, que são entradas recebidas através das suas conexões. Segundo Braga et al. (2000), o modelo de neurônio proposto por McCulloch e Pitts (MCP) é uma simplificação do que se sabia então a respeito do neurônio biológico. Sua descrição matemática resultou em um modelo com  $n$  terminais de entrada  $x_1, x_2, \dots, x_n$  (que representam os dendritos) e apenas um terminal de saída  $y$  (representando o axônio). Para emular o comportamento das sinapses, os terminais de entrada do neurônio têm pesos acoplados  $w_1, w_2, \dots, w_n$  cujos valores podem ser positivos ou negativos, dependendo das sinapses serem excitatórias ou inibitórias. O efeito de uma sinapse particular  $i$  no neurônio pós-sináptico é dado por  $x_i w_i$ . Os pesos determinam “em que grau” o neurônio deve considerar sinais de disparo que ocorrem naquela conexão.

Um neurônio biológico dispara quando a soma dos impulsos que ele recebe ultrapassa o seu limiar de excitação (*threshold*). O corpo do neurônio, por sua vez, é emulado por um mecanismo simples que faz a soma dos valores  $x_i w_i$  recebidos pelo neurônio (soma ponderada) e decide se o neurônio deve ou não disparar (saída igual a 0 ou a 1) comparando a soma obtida ao limiar ou *threshold* do neurônio. No modelo MCP, a ativação do neurônio é obtida por meio da aplicação de uma “função de ativação”, que ativa ou não a saída dependendo do valor da soma ponderada das suas entradas. Na descrição original do modelo MCP, a função de ativação é dada pela função de limiar descrita por  $\sum_{i=1}^n x_i w_i \geq \theta$ ,

onde  $n$  é o número de entradas do neurônio,  $w_i$  é o peso associado à entrada  $x_i$  e  $\theta$  é o limiar (*trheshold*) do neurônio.

A partir do modelo proposto por McCulloch e Pitts, foram derivados vários outros modelos que permitem a produção de uma saída qualquer, não necessariamente zero ou um, e com diferentes funções de ativação. Existem outros componentes levados em conta na escolha do tipo de rede neural que devem ser utilizados na resolução de um determinado problema. Dentre eles, pode-se citar a arquitetura da rede e o tipo de aprendizado utilizado. A seguir, serão descritas algumas funções de ativação, arquiteturas de redes e tipos de aprendizado.

### Funções de Ativação

As funções de ativação mais utilizadas são: a função linear, a função rampa, a função degrau (*step*) e a função sigmoideal (BRAGA, 2000).

A função de ativação linear é definida por  $y = \alpha x$ , onde  $\alpha$  é um número real que define a saída linear para os valores de entrada ( $y$  é a saída e  $x$  é a entrada).

A função linear pode ser restringida para produzir valores constantes em uma faixa  $[-\gamma, +\gamma]$ , e neste caso a função passa a ser a função rampa, definida como:

$$y = \begin{cases} +\gamma & \text{se } x \geq +\gamma \\ x & \text{se } |x| < +\gamma \\ -\gamma & \text{se } x \leq -\gamma \end{cases} .$$

A função passo é similar a uma função sinal no sentido de que a função produz a saída  $+\gamma$  para os valores de  $x$  maiores que zero, caso contrário, a função produz o valor  $-\gamma$ .

$$\text{A função degrau é definida por } y = \begin{cases} +\gamma & \text{se } x > 0 \\ -\gamma & \text{se } x \leq 0 \end{cases} .$$

A função sigmoidal, conhecida também como *S-shape* é uma função de forma sigma, limitada e monotônica. É possível definir várias funções sigmoidais, uma das mais importantes é a função logística que é definida como  $y = \frac{1}{1 + e^{-x/T}}$ , onde o parâmetro  $T$  determina a suavidade da curva.

## **Aprendizado**

O aprendizado de uma rede neural envolve a modificação do seu padrão de interconexão, que, em princípio, pode ser feita de três maneiras distintas: estabelecimento de novas conexões, amputação de conexões existentes e alteração dos pesos das conexões. Um conjunto de procedimentos bem definidos para adaptar parâmetros de uma RNA, para que a mesma possa *aprender* uma determinada função, é chamado de *algoritmo de aprendizado*. Existem diversos algoritmos que diferem pela maneira que o ajuste dos pesos é feito.

O conhecimento da rede é adquirido por meio de um processo de treinamento onde valores de pesos associados a conexões entre as unidades são ajustados através de um algoritmo de treinamento. Durante o treinamento, exemplos são apresentados à RNA, que por sua vez é especificada principalmente pela sua topologia, pelas características de seus neurônios e pelo seu algoritmo de treinamento. O processo de aprendizado varia de acordo com a topologia da rede.

Diversos métodos para treinamento das redes foram desenvolvidos, podendo ser agrupados em dois paradigmas principais: aprendizado supervisionado e aprendizado não supervisionado.

No aprendizado supervisionado, o aprendizado da rede é feito com o conhecimento prévio do resultado desejado, ou seja, são fornecidos, para a rede, o conjunto de dados de entrada e as respectivas respostas desejadas. A rede tem sua saída corrente (calculada) comparada com a saída desejada, recebendo informações sobre o erro da resposta atual. A cada padrão de entrada submetido à rede compara-se a resposta desejada (que representa uma ação ótima para ser realizada pela rede) com a resposta calculada, ajustando-se os pesos das conexões de maneira a minimizar o erro. A minimização é incremental, já que pequenos ajustes são feitos nos pesos a cada etapa de treinamento de tal forma que estes

caminhem, se houver solução possível, para única solução. A soma dos erros quadráticos de todas as saídas é normalmente utilizada como medida de desempenho da rede e também como função de custo a ser minimizada pelo algoritmo de treinamento. Os exemplos mais conhecidos de algoritmos de treinamento para aprendizado supervisionado são a regra delta (WIDROW; HOFF, 1960) e a sua generalização para redes de múltiplas camadas, o algoritmo *backpropagation*.

Por sua vez, no aprendizado não supervisionado, a rede aprende com os próprios dados de entrada (somente estímulos de entrada são mostrados à rede), ou seja, este algoritmo não requer o conhecimento das saídas. A rede, nesse caso, é auto-organizável, isto é, ela se organiza internamente de tal forma que cada elemento de processamento de resposta, estrategicamente, a um diferente conjunto de entradas. Um exemplo de rede que utiliza esse aprendizado é a de Kohonen (KOHONEN, 1982).

### **Principais Arquiteturas de RNA**

Segundo Braga et al. (2000), a definição de uma RNA é um parâmetro importante na sua concepção, uma vez que ela restringe o tipo de problema que pode ser tratado pela rede. Redes com uma única camada de nodos MCP, por exemplo, só podem resolver problemas linearmente separáveis. Redes recorrentes, por sua vez, são mais apropriadas para resolver problemas que envolvem processamento temporal. Fazem parte da definição da arquitetura os seguintes parâmetros: número de camadas da rede, número de nodos em cada camada, tipo de conexão entre os nodos e topologia da rede.

Quanto ao número de camadas, podem-se ter redes de camada única, onde só existe um nó entre qualquer entrada e qualquer saída e redes de múltiplas camadas, às quais existe mais de um neurônio entre alguma entrada e alguma saída da rede.

Por sua vez, os nodos podem ter conexões do tipo *feedforward* ou *feedback*. Nas conexões do tipo *feedforward* ou acíclica, a saída de um neurônio na  $i$ -ésima camada da rede não pode ser usada como entrada de nodos em camadas de índice menor ou igual a  $i$ . Já, as do tipo *feedback* ou cíclica, podem ser utilizadas como entrada de nodos em camadas de índice menor ou igual a  $i$ .

Para solução de problemas não linearmente separáveis apontados por Minsky e Papert, uma ou mais camadas de nodos intermediários (entre as camadas de entrada

e saída) são necessárias. Entre as RNA multicamadas, destacam-se as redes *Multilayer Perceptron* (MLP) e as redes *Radial Basis Functions* (RBF).

As redes MLP possuem uma ou mais camadas de nodos intermediários que computam funções não lineares a partir de entradas ponderadas pelos valores dos pesos das conexões associadas às mesmas. A Figura 4 ilustra uma RNA MLP típica.

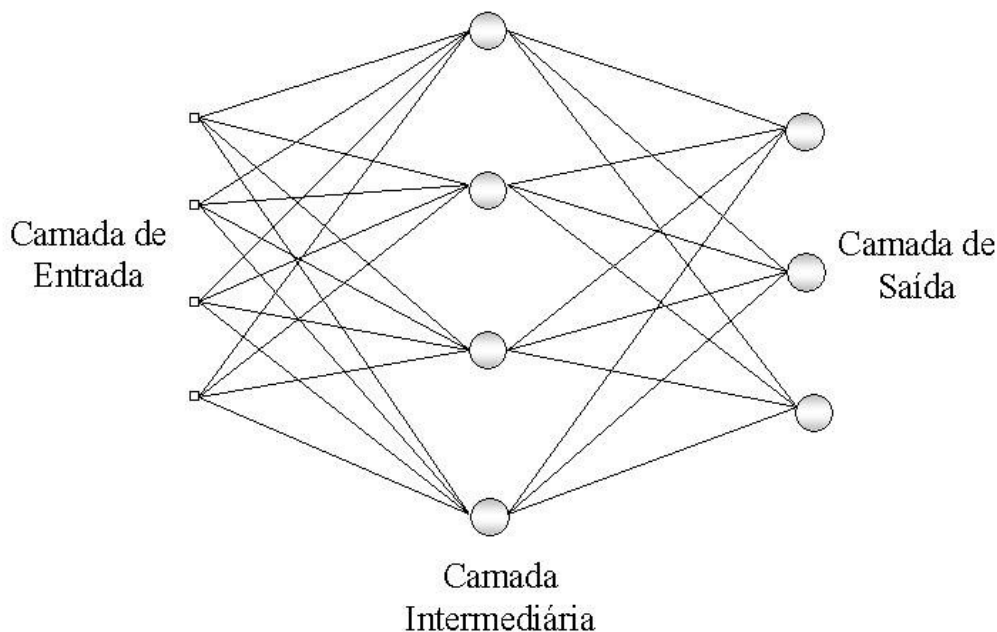


Figura 4. Rede Neural Artificial *Multilayer Perceptron* típica.

O treinamento de uma rede MLP é geralmente realizado por intermédio do algoritmo *backpropagation* (RUMELHART, 1986), um dos algoritmos mais utilizados em RNA. Como no caso das redes *Perceptron*, o algoritmo *backpropagation* utiliza os dados de treinamento para ajustar os pesos da rede por um mecanismo de correção de erros. O *backpropagation* consiste na iteração de duas etapas: *forward* e *backward*. Na fase *forward*, um exemplo de treinamento é apresentado à rede, que produz uma saída. Na fase *backward*, que percorre a RNA da camada de saída em direção à camada de entrada, os pesos das conexões da rede são modificados a partir do erro calculado entre a saída desejada e a produzida pela RNA.

O algoritmo a seguir apresenta um pseudocódigo do *backpropagation*:

1. Inicializar pesos e parâmetros.
2. Repetir até o erro ser mínimo ou até a realização de um dado número de ciclos

#### 2.1 Para cada padrão de treinamento X

2.1.1 Definir a saída da rede através da fase *forward*.

2.1.2 Comparar saídas produzidas com as saídas desejadas.

2.1.3 Atualizar pesos do nodo através da fase *backward*.

Por sua vez, as redes RBF possuem em geral apenas uma camada intermediária de nodos. Estes nodos representam aproximações locais da função objetivo por meio de funções Gaussianas (radiais). Esta característica aproxima as redes RBF das técnicas baseadas em exemplos (MITCHELL, 1997). As estimativas locais obtidas são então linearmente combinadas pelos nodos da camada de saída. O treinamento das redes RBF é tipicamente composto de duas etapas.

Na primeira, as funções radiais (associadas aos nodos da camada intermediária) são determinadas. Este processo pode ser realizado, por exemplo, por intermédio de técnicas não supervisionadas. Na segunda etapa, os pesos da rede são ajustados de forma supervisionada, o que pode ser feito com o uso do algoritmo *backpropagation*.

Tanto as redes MLP quanto as RBF são aproximadoras universais de funções, sendo capazes de representá-las de formas arbitrárias. Porém, para uma mesma aproximação não-linear, as redes MLP podem requerer um número menor de parâmetros a serem ajustados (HAYKIN, 1999). Apesar disso, as redes RBF apresentam, em geral, um tempo de treinamento reduzido quando comparado ao das redes MLP (MITCHELL, 1997).

## 2.4 Estatística Multivariada

A análise multivariada de dados é constituída de métodos, nos quais os fenômenos são estudados a partir de valores coletados ou mensurados de muitas variáveis. A necessidade de compreensão da estrutura de variabilidade entre as diversas variáveis faz com

que o procedimento analítico multivariado seja complexo ou algumas vezes de difícil entendimento (JOHNSON; WICHERN, 2002).

Os objetivos gerais da análise multivariada podem ser resumidos em:

- a. redução de dados ou simplificação natural;
- b. ordenação e agrupamento;
- c. investigação da dependência entre variáveis;
- d. predição;
- e. construção e teste de hipóteses.

Os modelos multivariados possibilitam ao pesquisador, sem quebrar a estrutura geral de variação, inferir a respeito de uma hipótese geral sobre um determinado fenômeno. No entanto, sua utilização adequada depende do bom conhecimento das técnicas e das suas limitações. A frase utilizada por Marriot (1974) descreve bem este fato: “Não há mágica com os métodos numéricos e que, apesar de serem uma importante ferramenta para análise e interpretação de dados, não devem ser utilizados como máquinas automáticas de encher lingüiça, transformando massas numéricas em pacotes de fatos científicos”.

As técnicas multivariadas são aplicadas nas mais diversas áreas do conhecimento, tais como, medicina, sociologia, biologia e agronomia (MARDIA *et al.*, 1997; LITTEL *et al.*, 2000; SINGER ; ANDRADE, 2000).

Para Johnson e Wichern (2002), os dados multivariados provêm de um experimento onde são observados  $p > 1$  variáveis ou características em cada unidade observacional ou parcela. A representação genérica de uma unidade elementar da estrutura dos dados multivariados é feita com a notação  $x_{jk}$  para indicar a resposta da  $j$ -ésima unidade experimental na  $k$ -ésima variável mensurada. Conseqüentemente, estas medidas de  $p$  variáveis em  $n$  unidades amostrais ou experimentais podem ser representadas conforme arranjo retangular matricial, denominado de  $\mathbf{X}$ , com  $n$  linhas e  $p$  colunas da seguinte forma:



$$X = \begin{bmatrix} x_{11} & x_{12} & \cdots & x_{1k} & \cdots & x_{1p} \\ x_{21} & x_{22} & \cdots & x_{2k} & \cdots & x_{2p} \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ x_{j1} & x_{j2} & \cdots & x_{jk} & \cdots & x_{jp} \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ x_{n1} & x_{n2} & \cdots & x_{nk} & \cdots & x_{np} \end{bmatrix},$$

onde o vetor linha representa as respostas de uma unidade experimental e o vetor coluna, as respostas de uma dada característica nas diferentes parcelas.

A organização dos dados em arranjos facilita a exposição e permite que os cálculos sejam efetuados de uma forma ordenada e eficiente. Os ganhos são na operacionalização dos cálculos como operações com matrizes e vetores e a fácil implementação computacional. Existem diversas técnicas de análise multivariada de dados: análise de agrupamento, análise de fatores, análise de correlação canônica, análise discriminante de Fisher, análise de componentes principais, entre outras. Segundo Johnson e Wichern, citado em Simeão(2007) a escolha de qual técnica utilizar, depende da natureza do problema a ser resolvido.

### 2.4.1 Análise de Componentes Principais

A Análise de Componentes Principais (ACP) ou *Principal Component Analysis (PCA)* foi descrita primeiramente por Karl Pearson, em 1901. Em 1933, Hotteling reformulou a técnica, passando a ser conhecida como Técnica Transformada de Hotteling (HOTTELIN, 1933).

A ACP tem por objetivo substituir um conjunto de variáveis correlacionadas por um conjunto de novas variáveis não correlacionadas entre si, as quais são combinações lineares das variáveis originais e apresentadas em ordem decrescente da magnitude de suas variâncias. Certos tipos de pesquisas, como é o caso das que fazem uso do processamento digital de imagens apresentam alta correlação entre os *pixels* consecutivos e,

neste sentido, a ACP constituem-se em uma das ótimas aplicações para os algoritmos de decorrelação de dados. A teoria relativa a este tópico multivariado foi descrita nas consultas bibliográficas baseadas em Hotelling(1936), Anderson (1963), Anderson (1984), Rencher(1992) e Johnson e Wichern (2002).

Os componentes principais caracterizam-se por combinações lineares de  $p$  variáveis aleatórias  $X_1, X_2, \dots, X_p$ , que geometricamente representam a seleção de um novo sistema de eixos coordenados obtido por rotações do sistema de eixos original. Os novos eixos representam as direções de máxima variabilidade. Os componentes principais dependem somente da matriz de covariância  $\Sigma$  (ou da matriz de correlação  $\rho$ ) de  $X_1, X_2, \dots, X_p$ . Seu desenvolvimento não requer pressuposições distribucional de normalidade multivariada, mas, possuem interpretações úteis em termos da elipsóide de densidade, se a normalidade dos dados existir.

Seja o vetor aleatório  $\underset{\sim}{X}^t = [X_1, X_2, \dots, X_p]$  amostrado de uma população com matriz de covariância  $\Sigma$ , cujos autovalores são  $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_p \geq 0$ . A matriz de dados  $X$  é, portanto, composta por  $p$  colunas e  $n$  linhas, onde  $n$  corresponde ao número de unidades experimentais do vetor  $\underset{\sim}{X}$  de variáveis aleatórias  $X_i$ . Então, os componentes principais  $(Y_1, Y_2, \dots, Y_p)$  são as combinações lineares dadas por

$$Y_1 = \underset{\sim}{e}_1^t \underset{\sim}{X} = e_{11}X_1 + e_{12}X_2 + \dots + e_{1p}X_p$$

$$Y_2 = \underset{\sim}{e}_2^t \underset{\sim}{X} = e_{21}X_1 + e_{22}X_2 + \dots + e_{2p}X_p$$

⋮

$$Y_p = \underset{\sim}{e}_p^t \underset{\sim}{X} = e_{p1}X_1 + e_{p2}X_2 + \dots + e_{pp}X_p, \text{ ou matricialmente,}$$

$$\begin{bmatrix} Y_1 \\ \vdots \\ Y_p \end{bmatrix} = \begin{bmatrix} e_{11} & \dots & e_{1p} \\ \vdots & & \vdots \\ e_{p1} & \dots & e_{pp} \end{bmatrix} \begin{bmatrix} X_1 \\ \vdots \\ X_p \end{bmatrix}, \text{ ou seja } \underset{\sim}{y} = E \underset{\sim}{X}^t$$

As variáveis  $Y_k$  possuem, respectivamente, variância e covariância dadas pelas equações

$$Var(Y_k) = Var(e_{\sim k}^t X) = e_{\sim k}^t Var(X) e_{\sim k} = e_{\sim k}^t \sum_{\sim k} e e$$

$$Cov(Y_k, Y_{k'}) = Cov(e_{\sim k}^t X, e_{\sim k'}^t X) = e_{\sim k}^t \sum_{\sim k'} e_{\sim k'}, \text{ para } k=1, \dots, p \text{ e } k'=1, \dots, p.$$

Para determinar os vetores  $e_{\sim 1}, \dots, e_{\sim p}$ , considera-se a equação polinomial  $\det(\sum - \lambda I) = 0$ , cujas raízes são denominadas autovalores de  $\Sigma$  e os correspondentes vetores solução do sistema homogêneo  $(\sum - \lambda I)e_{\sim k} = 0$ , os respectivos autovetores.

Assim, defini-se o primeiro componente principal ( $Y_1$ ) expresso em obtido a partir da matriz de covariância  $\Sigma'$ , do vetor aleatório  $X$ , como par resultante de maior autovalor  $\lambda_1$  e autovetor  $e_{\sim 1}$  descritos por:  $Y_1 = e_{\sim 1}^t X = e_{11} X_1 + e_{12} X_2 + \dots + e_{1p} X_p$ , sendo  $Var(Y_1) = \lambda_1$  (máximo dos autovalores).

Sucessivamente, são determinados os demais componentes  $Y_2(\lambda_2, e_{\sim 2})$  com  $\lambda_2$  o segundo máximo  $\lambda_2 \leq \lambda_1$ , até  $Y_p(\lambda_p, e_{\sim p})$  com  $\lambda_p \leq \lambda_{p-1} \leq \dots \leq \lambda_1$ .

A porcentagem de variação total explicada pelo k-ésimo componente principal é dada por  $\%Var\_Explicada(Y_k) = \frac{\lambda_k}{\sum_{i=1}^p \lambda_i} \times 100\%$ .

Em muitas situações, principalmente quando as variáveis possuem forte correlação entre si, 80 ou 90% da variância total dos dados originais pode ser acumulado nos dois ou três primeiros componentes principais, de maneira a permitir uma redução considerável de dimensionalidade sem grande perda de informação biológica dos dados.

Uma outra consideração algébrica que deve ser contemplada consiste na influência da escala de mensuração das variáveis na obtenção dos componentes. Neste caso, a normalização (padronização) se faz necessária, pois as variáveis originais representam valores em escalas distintas. A técnica mais comum de obter os componentes principais nesta

situação remete à padronização das variáveis originais dadas por:  $Z_i = \frac{X_i - \mu_i}{\sqrt{\sigma_{ii}}}$  para  $i=1, \dots, p$ , onde  $\mu_i$  e  $\sigma_{ii}$  são respectivamente, média e variância da variável aleatória  $X_i$ .

Considerar a notação matricial,  $\underline{\tilde{Z}} = V^{-1/2}(\underline{\tilde{X}} - \underline{\tilde{\mu}})$ , onde  $V^{-1/2}$  é uma matriz diagonal com os elementos da diagonal  $1/\sqrt{\sigma_{ii}}$ , sabe-se que  $E(\underline{\tilde{X}}) = \underline{\tilde{\mu}}$  e  $COV(\underline{\tilde{X}}) = \underline{\tilde{P}}$ . Então  $E(\underline{\tilde{Z}}) = \underline{0}$  e  $COV(\underline{\tilde{Z}}) = \underline{P}$ , onde  $\underline{P} = COR(\underline{\tilde{X}})$ .

Em relação ao uso da técnica dos componentes principais na redução do espaço paramétrico, pode-se resumir o procedimento de obtenção dos componentes principais na seguinte ordem de passos, conforme citados em Messetti(2007):

1. Se as variáveis originais  $X_1, X_2, \dots, X_p$  representam valores em escalas distintas, então essas variáveis devem ser normalizadas de tal forma que tenham média nula e variância unitária.
2. Calcula-se a matriz de covariância das variáveis. Se a condição do passo 1 for satisfeita, então esta matriz de covariância é na verdade, a matriz de correlação das variáveis originais.
3. Calculam-se os pares de autovalor e autovetor da matriz do passo 2. Estes pares devem ser ordenados em ordem decrescente de autovalores.
4. Eliminam-se os componentes principais correspondentes aos autovalores que são desprezíveis com relação à variância total dos dados originais (SILVA, 2005),

## 2.5 Aplicações das técnicas utilizadas na Ciência Agronômica

Considerou-se neste item, a revisão de literatura de produções científicas da área de ciências agronômicas e assemelhadas que utilizam o processamento

digital de imagens, as técnicas de análise multivariada e redes neurais artificiais como suporte inferencial e descritivo para a discussão dos resultados biológicos.

### 2.5.1 Processamento Digital de Imagens

Sena Júnior et al. (2001) desenvolvem um algoritmo de processamento e análise de imagens digitais para identificação de plantas de milho atacadas pela lagarta do cartucho, o qual consistiu em duas etapas de classificação dos objetos presentes em lavoura de milho. Na primeira etapa, denominada classificação grosseira, utiliza-se a técnica de limiarização em blocos de imagens com 60 x 60 pixels de dimensão e, na segunda, denominada classificação refinada, empregam-se redes neurais artificiais em blocos de 3 x 3 pixels de dimensão. A exatidão de cada etapa do algoritmo foi acessada por meio da determinação da matriz de contigência, com base em 80 e 75 blocos, para a classificação grosseira e refinada, respectivamente. O algoritmo apresentou índice de exatidão de 80, 74%.

Prates e Fernandes (2001) utilizam um software de processamento digital de imagens, o *AreaScan*, para avaliar a taxa de expansão de lesões de *Bipolaris sorokiniana* em folhas de trigo, variando-se cultivares e temperaturas. O software conseguiu distinguir efetivamente a área com lesão, mostrando-se como uma ferramenta poderosa na busca de cultivares mais resistentes a essa doença.

Sena Júnior et al. (2003) implementam dois métodos automáticos de limiarização para identificação de plantas de milho atacadas pela lagarta do cartucho. Utilizaram-se imagens digitais de plantas atacadas e não-atacadas, em três épocas, correspondendo a diferentes dias após a infestação. As imagens processadas com o índice de excesso de verde normalizado são limiarizadas automaticamente e comparadas com a limiarização manual das mesmas imagens. Os resultados obtidos pelos dois métodos de limiarização de imagens foram satisfatórios, apresentando média acima de 99% de exatidão global.

Spósito et al. (2004) elaboram uma escala diagramática, com o uso do software SIARCS, para avaliar a severidade da Mancha Preta em frutos cítricos. Para isto, coletaram-se imagens digitais de 50 frutos com ampla variação da severidade da doença. Os

níveis mínimo e máximo de severidade foram determinados de acordo com a maior frequência observada de tecido doente nos frutos coletados. Essa pesquisa contribuiu bastante para melhorar a precisão de avaliação da doença, de maneira a propiciar uma melhor estratégia de controle da Mancha preta de citrus.

Coelho Filho et al. (2005) aplicam o processamento digital de imagens na estimativa da área foliar de plantas de lima ácida, baseando-se em imagens digitais da área frontal de cada planta e informações de variáveis biométricas, correlacionadas com a contagem total de folhas e a área foliar média.

Lupetti et al. (2005) utilizam a análise digital de imagens para a quantificação do escurecimento de tecidos vegetais em diferentes frutos. Observou-se que cada fruto apresenta uma condição diferente que melhor minimiza o processo oxidativo.

Moya et al. (2005) fazem uso da análise digital de imagens para a validação do método de análise visual da severidade de míldio em abóbora. No entanto, não obtiveram uma boa confiabilidade devido a problemas na resolução das imagens digitais.

Tanska et al. (2005) aplicam o método das análises digitais para identificar a coloração ou as impurezas de sementes de cereais com medidas geométricas e de cores das imagens. Verificou-se que as variações das medidas geométricas das sementes são menores que as variações de cores e que não se conseguem distinguir, pela análise de cores, os diferentes estágios de maturação das sementes.

Corkidi et al. (2006) avaliam a antracnose em manga utilizando-se técnicas tridimensionais de análise de imagem para quantificar lesões em frutos. As técnicas foram aplicadas para avaliar o desenvolvimento e severidade da antracnose, causada pelo fungo *Colletotrichum gloesporioides*. O método demonstrou bom desempenho e pode ser adaptado para outras doenças.

Gomes Filho et al. (2006) utilizam o processamento digital de imagens para quantificar a incidência da mancha fisiológica em frutos do mamoeiro (MFM), no intuito de aferir o método das notas. Os resultados mostram que o método das notas pode ser utilizado com segurança, mostrando-se preciso para quantificar o nível de incidência da MFM.

Teixeira et al. (2006), utilizando a análise de imagens digitais, estudam o vigor de lotes de sementes de milho por meio do teste de crescimento de plântulas. Com os resultados, verificou-se que a técnica digital possibilita a associação dos dados obtidos

no processamento a eventuais diferenças de vigor existentes em lotes de sementes de milho, de maneira similar a outros métodos destinados à avaliação do vigor de sementes da referida espécie.

Baesso et al. (2007) avaliam o uso de índices espectrais, retirados de imagens digitais, para discriminar diferentes doses de nitrogênio em feijoeiro. Para isso, foram desenvolvidas funções discriminantes quadráticas, tendo como vetores de entrada as médias dos *pixels* de diferentes combinações dos quatro índices espectrais testados. Três diferentes tamanhos de blocos de imagem foram testados 9 x 9, 20 x 20 e 40 x 40 *pixels*. Os melhores resultados foram alcançados pelos blocos de 9 x 9 e 20 x 20 *pixels*, apresentando classificação com acerto de 94% e 96%, respectivamente.

Teixeira et al. (2007) realizam um estudo para desenvolver, em plataforma gráfica *Scil-Image*, uma solução computacional orientada ao processamento do tamanho, com análise da largura e do comprimento de sementes de milho digitalizadas via leitura ótica em escaner, partindo-se de imagens de sementes de um mesmo cultivar. Com esse método, analisou-se a dimensão das sementes rapidamente, com tempos de processamento das imagens em torno de 3 segundos, partindo-se de imagens de 50 sementes.

Cruz et al. (2008), com o objetivo de comparar dois classificadores de imagens para a estimativa da cobertura vegetal do solo, avaliam as coberturas proporcionadas pela semeadura de leguminosas e de gramíneas, sob diferentes espaçamentos, preparo do solo e condições de céu com e sem nuvens. Para isso, tomaram-se fotografias das parcelas dos 15 aos 85 dias após a semeadura, para posterior análise utilizando-se o Sistema Integrado para Análise de Raízes e Cobertura do Solo (SIARCS) e um algoritmo baseado na emissividade das bandas do verde e do vermelho (SEROBIN). As exatidões globais foram de 0,96 e 0,92, para as classificações realizadas com os programas SIARCS e SEROBIN, respectivamente, não havendo, no entanto, diferença estatística entre os dois classificadores utilizados, de acordo com o teste Z aplicado a 5% de probabilidade.

### 2.5.2 Redes Neurais Artificiais

Yang et al. (2000) aplicam RNA, treinadas com o algoritmo *backpropagation*, no desenvolvimento de um modelo capaz de distinguir plantas jovens de milho de plantas daninhas. Foram utilizados como entrada índices de cores associados com pixels da imagem. Foram coletadas no campo imagens digitais com 756 x 504 pixels de dimensão e, então, foram cortadas imagens de 100 x 100 pixels de dimensão, retratando somente uma planta, quer seja um pé de milho ou uma planta daninha. Utilizaram-se 40 imagens de cada classe (milho e planta daninha) para treinamento, com mais outras 20 imagens para teste do modelo. A taxa de acerto se aproximou a 100% para milho e 80% para planta daninha, mostrando que um sistema de reconhecimento baseado em RNA é potencialmente preciso na pulverização de herbicidas em campos agricultáveis.

Varela et al. (2002) desenvolvem um programa computacional para estimar a cobertura de solo, utilizando-se RNA treinadas com o algoritmo *backpropagation*. Os dados para treinamento das redes neurais foram obtidos de imagens digitais coloridas. Foram testadas cinco arquiteturas de redes e a que apresentou melhor resultado foi utilizada no programa computacional para classificação. O classificador apresenta índice de exatidão de 82,10%, cujo resultado mostra que as redes neurais podem ser empregadas em programas computacionais para separar feições onde a diferença entre a intensidade de brilho não permite a aplicação de técnicas de limiarização.

Simões e Costa (2003) realizam a classificação de laranjas baseadas em padrões visuais com a utilização de RNA. A arquitetura estruturada para classificação das frutas apresentou quatro etapas: classificação de pixels, segmentação da imagem, extração de padrões e comparação de padrões encontrados.

Pernomian et al. (2004) apresentam um trabalho que enfoca o reconhecimento de plantas daninhas em tempo real para o desenvolvimento do sistema automático de pulverização. Utilizam-se técnicas de processamento digital de imagens e RNA para realizar a identificação da planta invasora Picão Preto. Coletaram-se imagens digitais com o uso de máquinas fixadas em equipamentos agrícolas. A seguir, extraíram-se os componentes principais com o uso de transformada de Hotteling, para servirem como entrada na classificação da rede neural.



Chakraborty et al. (2004) desenvolvem modelos com RNA para realizar a predição da severidade de antracnose em pastagens *Stylosanthes scabra* causada pelo *Colletotrichum gloeosporioides* baseados em dados meteorológicos. Os dados foram coletados e analisados em sete campos diferentes dos países Austrália, Brasil e Colômbia; buscou-se, com o modelo, realizar a predição do risco da antracnose em outros locais.

Hahn et al. (2004) utilizam detecção espectral e RNA na discriminação de esporos de *Rhizopus stolonifer* em frutos maduros de tomates vermelhos a partir de reflectância óptica. As assinaturas espectrais são examinadas pela análise discriminante e comparadas às RNA. As RNA mostraram ter mais acurácia que as equações discriminantes. Esse método de detecção espectral pode substituir testes de laboratório com inúmeras vantagens, entre elas a rapidez de detecção que pode ser reduzida em algumas horas.

Kavdir e Guyer (2004) avaliam o desempenho de diferentes classificadores: RNA, Árvores de Decisão, Bayesiano e K-Vizinhos mais Próximos aplicados ao problema de seleção de frutos. Foram coletadas imagens digitais de duas espécies de maçãs, incluindo os frutos bons e os descartados. Também, compararam-se o processo de extração de características de textura da imagem com o histograma. Como resultado, verificou-se que as RNA obtiveram melhor desempenho, adicionadas ao uso de características de textura.

Burks et al. (2005) comparam o desempenho de três algoritmos de RNA aplicados ao reconhecimento de plantas daninhas. Foram coletadas 40 imagens de seis classes diferentes (cinco diferentes espécies e uma sendo a superfície de solo). De cada imagem foram extraídos 33 atributos de entrada. O algoritmo *backpropagation* foi o que apresentou melhor acurácia (97%).

Granitto et al. (2005) comparam o desempenho de um classificador Bayesiano com um de RNA, tanto individualmente quanto em comitês, aplicados à identificação automática de sementes de 236 espécies de plantas daninhas. Utilizaram-se características de forma, tamanho, cor e textura das imagens das sementes, obtidas com técnicas do processamento digital de imagens. O classificador bayesiano apresentou uma performance tão boa quanto ao de RNA.

Schoeninger (2006) utiliza RNA e imagens do satélite IKONOS II para obter mapas temáticos para estimativas de biomassa arbórea e da quantidade de carbono

orgânico armazenado em uma Floresta Ombrófila Densa. Para tal, foi feito um levantamento de amostras, que foram identificadas e uma parte das árvores foram abatidas, mensuradas e pesadas em toda sua parte aérea para a determinação de sua biomassa arbórea e quantidade de carbono armazenado. As estimativas obtidas foram relacionadas com dados oriundos das bandas das imagens do satélite IKONOS II. Verificou-se o desempenho das RNA e de equações de regressão lineares na quantificação de biomassa arbórea e na quantidade de carbono armazenado. A arquitetura de RNA que apresentou melhores resultados foi com 12 neurônios na camada de entrada e 4 na camada de saída, para um limiar de erro de 0,01, para ambas as variáveis estimadas. O erro percentual médio em relação às amostras de verificação foi de 3,73 e 3,59%, para biomassa e quantidade de carbono, respectivamente. A melhor equação de regressão linear apresentou erro padrão da estimativa em porcentagem na ordem de 29,8 % para ambas as variáveis estimadas. A aplicação de Redes Neurais Artificiais mostrou-se mais exata na estimativa da biomassa e da quantidade de carbono do que as equações de regressão lineares ajustadas.

Huang (2007) aplica RNA e técnicas do processamento digital de imagens para detectar e classificar doenças em plântulas de orquídea. Para tal, utilizaram-se características de cores e texturas das imagens digitais. A RNA com o algoritmo *backpropagation* foi empregada na classificação das doenças podridão mole, mancha marrom e podridão negra e em plântulas não infectadas. A rede neural conseguiu uma acurácia de 89,6% para detecção e classificação e 97,2% para classificação das doenças.

Picoli (2007), em um estudo, objetiva estimar a produtividade da cana-de-açúcar na Usina Catanduva, utilizando variáveis quantitativas e qualitativas em um modelo de agregados de RNA ou *ensembles*. Este modelo utiliza uma série de variáveis meteorológicas e agrônômicas, sendo que uma delas é o índice de área foliar (IAF), cujos valores foram estimados, para cada talhão de cana, a partir do NDVI das imagens MODIS obtidas ao longo do período de intenso crescimento da cultura canavieira. O modelo explicou 66% da variabilidade da produtividade dos talhões com cana soca, cuja média foi de 81,9 t ha<sup>-1</sup> e erro quadrático médio de 13,9 t ha<sup>-1</sup>.

NÄÄS et al. (2008) realizam uma pesquisa que implementa um algoritmo baseado em RNA, capaz de reconhecer vocalizações relacionadas com padrões indicativos de bem-estar. O software Matlab foi utilizado na implementação da rede. Foi

selecionado o algoritmo *backpropagation* para treinar a rede com os seguintes critérios de parada: máximo de 5.000 iterações ou soma quadrática do erro menor que 0,1. O algoritmo foi capaz de reconhecer, por meio da intensidade do ruído, a situação inerente ao risco de redução do bem-estar dos leitões.

### 2.5.3 Estatística Multivariada

Michereff et al. (2003) utilizam a análise multivariada para estudar a variabilidade de isolados de *Alternaria brassicicola*. Os isolados foram coletados de cultivos comerciais de crucíferas do Estado de Pernambuco e cada isolado foi inoculado em planta de repolho. Não se verificaram correlações significativas entre as variáveis associadas à doença com as demais variáveis. A análise de agrupamento utilizando como medida de similaridade a distância euclidiana por meio do algoritmo UPGMA (agrupamento aos pares pela média não ponderada) não permitiu a separação dos 38 isolados do patógeno em grupos de similaridade, sugerindo grande variabilidade nas populações.

Soares et al. (2004) estudam 58 populações de *Rotylenchulus reniformis* de amostras de solo e raízes de diferentes culturas e inoculadas em plantas de algodoeiro (*Gossypium hirsutum*) cv. COODETEC 402 e de mamona (*Ricinus communis*), mantidas em vasos de argila em casa de vegetação do Departamento de Fitossanidade da UNESP/FCAV, Campus de Jaboticabal - São Paulo. Neste trabalho, realizou-se um estudo morfométrico comparativo das populações ao microscópio óptico composto, seguido da ordenação das populações segundo análises multivariadas de agrupamento e de componentes principais. Foram consideradas 11 variáveis morfométricas em 10 fêmeas jovens de cada população e sete variáveis derivadas. A amplitude de variação de caracteres morfométricos em populações brasileiras desse nematóide tais como, comprimento do estilete e forma da cauda, é maior que em populações da mesma espécie de outras regiões do mundo. Os dados obtidos confirmam que o comprimento do estilete e presença de machos é suficiente para identificação de *R. reniformis*, e que esta é a espécie do grupo predominante nos agroecossistemas brasileiros. A análise de componentes principais mostrou quais variáveis foram mais discrepantes. A análise de agrupamento dividiu a população em dois grandes grupos.

Nascimento et al. (2006) utilizam a análise de agrupamento pelo método UPGMA (agrupamento aos pares pela média não ponderada) para avaliar a reação de 20 clones de videira ao cancro bacteriano, baseada nos componentes epidemiológicos. Obteve-se como resultado da análise de agrupamento a construção de três grupos de similaridade entre os clones de copa e porta-enxerto, quando considerado como ponto de fusão de 50% da distância total verificada.

Pydipati et al. (2006) aplicam o processamento digital de imagens e a análise discriminante para detectar doença em folha de citrus. Primeiramente, utiliza-se o processamento digital de imagens para extração de características e, em seguida, a análise discriminante como técnica de classificação para as quatro classes existentes, três tipos de doenças e folhas saudias. Foram adquiridas 40 amostras de cada classe para cada lado da folha. Os conjuntos de imagens da frente e detrás das folhas foram tratados como problemas separados de classificação. As imagens de cada classe foram divididas em dois conjuntos de dados, consistindo de 20 amostras para treinamento e 20 para teste. Em média, os resultados de classificação para os conjuntos de testes foram 96,3% e 95,8%, respectivamente, para os conjuntos da frente e detrás das folhas.

Gómez et al. (2006) utilizam técnicas multivariadas de componentes principais e discriminante linear para avaliar sensores de um nariz eletrônico aplicado à maturação do tomate. A análise discriminante linear apresentou melhores resultados que a técnica de componentes principais

Silva e Padovani (2006) mostram o uso da análise de componentes principais na experimentação agrônômica, ilustrando com dois exemplos. O primeiro exemplo aplica a ACP em análise de dados, cujo objetivo se refere ao estudo da variabilidade de isolados de patógenos, no desenvolvimento da planta da cultivar milho Doce de Cuba, onde a ACP se mostrou mais informativa do que a análise de variância univariada. Por sua vez, no segundo exemplo, aplicou-se a ACP na classificação de Cultivares de Batata, segundo um delineamento experimental multivariado, a qual se mostrou em concordância com método de classificação utilizado pelo EMBRAPA.

Messetti (2007), com o objetivo de avaliar a divergência genética de 12 populações de girassol do Banco de Germoplasma da EMBRAPA/Soja de Londrina, aplica de técnicas multivariadas (análise de componentes principais e análise de agrupamento). Pode-

se concluir pela existência da divergência genética, a detecção de quatro grupos geneticamente diferentes e caracterizados pelos escores médios.

Santos et al. (2007) avaliam a resistência parcial de genótipos de soja ao fungo *Phakopsora pachyrhizi*, utilizando procedimentos multidimensionais para o número médio de pústulas, a severidade e a área abaixo da curva de progresso da doença. Foram encontradas diferenças significativas entre os genótipos quanto ao número médio de pústulas e severidade, aos 12 dias após a inoculação. A análise de agrupamento permitiu a discriminação de genótipos parcialmente resistentes. Os genótipos G4, G41 e G42, referentes aos parentais Cristalina e IAC 100, foram detectados como os de maior resistência parcial à ferrugem da soja.

Sodré et al. (2007) aplicam a análise multivariada, com o uso de componentes principais e análise de agrupamento na caracterização físico-química de amostras de méis. Os resultados indicam condutividade elétrica e a sacarose aparentemente como as características que mais influenciam no agrupamento das amostras.

Sena Júnior et al. (2007) realizam uma pesquisa para avaliar a utilização de dados extraídos de imagens-índice, obtidos com 9 índices espectrais para identificação da dose de nitrogênio aplicada em plantas de trigo cultivadas em vasos. Para isso, foram avaliados classificadores multivariados criados pela combinação dos diferentes índices espectrais. Como resultados, observou-se que as características extraídas das imagens processadas com os índices espectrais permitiram uma classificação satisfatória, melhor que uma classificação ao acaso, das plantas de trigo de acordo com as doses de nitrogênio aplicadas. Embora os resultados de exatidão global e coeficiente *kappa* tenham sido iguais, a classificação multivariada com a informação relativa ao solo mostrou-se superior pelo maior acerto da classificação em cada classe.

Sanches et al. (2008) realiza um estudo com o objetivo de avaliar as imagens CCD/CBERS-2 quanto à possibilidade de discriminarem variedades de citros. Para isso, utilizou imagens CCD de três datas (30/05/2004, 16/08/2004 e 11/09/2004). Um modelo que integra os elementos componentes da cena citrícola sensoriada foi proposto com o objetivo de explicar a variabilidade das respostas das parcelas de citros em imagens orbitais do tipo CCD/CBERS-2. Foram feitas classificações pelos algoritmos *Isoseg* e *Maxver* e, de acordo com o índice *kappa*, concluiu que é possível se obterem exatidões qualificadas como

muito boas, sendo que as melhores classificações foram conseguidas com imagens da estação seca.

### 3. MATERIAIS E MÉTODOS

Na identificação dos sintomas da Sigatoka Negra, utilizou-se o processamento digital de imagens, a partir de método composto por quatro fases distintas de operacionalização: coleta e digitalização das amostras, segmentação e extração dos histogramas das imagens, seleção de atributos e, por último, classificação.

A coleta das amostras foi realizada por integrantes do Grupo de pesquisa em análise de dados da Unesp/Registro, nos meses de janeiro a fevereiro de 2008, em propriedades do município de Registro SP, nas quais havia bananais infectados pela doença (Sigatoka Negra). Antes da coleta, houve um contato prévio com os respectivos proprietários e, a partir do elucidamento do interesse do estudo, foi obtido o consentimento livre e esclarecido para a coleta em suas respectivas propriedades. Nas propriedades, foram identificadas, pelo procedimento do passeio casual, plantas infectadas das quais se extraiu parte das folhas que apresentavam os sintomas estudados. Para o monitoramento da enfermidade, torna-se essencialmente necessária a identificação dos estádios um, dois e três da doença e, para um melhor treinamento e extração do conhecimento, a base de dados também foi composta por classes que constituem os controles positivo e negativo representados por amostras de folhas com fitotoxidez por óleo mineral e sadias, respectivamente. Assim, as classes estudadas foram Sigatoka Negra nos estádios um, dois e três, fitotoxidez por óleo e folhas sadias (sem sintomas). Coletaram-se cerca de 20% da parte inferior direita das folhas um, dois, três e quatro, cujo material coletado foi levado ao laboratório de Defesa

Vegetal do Campus Experimental da Unesp de Registro e separado de acordo com a identificação de cada uma das classes consideradas.

De cada classe estudada, foram coletadas 20 amostras de forma geométrica quadrada de aproximadamente 2cm x 2cm, totalizando 100 amostras. As amostras foram, posteriormente, escaneadas em escaner de mesa da marca HP a uma resolução de 640 pixels e gravadas, separadamente, em arquivos “.jpeg”. Cada imagem de entrada consistiu, então, de um arquivo representando a digitalização de cada amostra das referidas classes.

A partir dos arquivos construídos, na seqüência procedeu-se com a segmentação e organização da distribuição de freqüência das intensidades de cores dos pixels. Para tal, arquitetou-se uma ferramenta computacional, com o uso do software HALCON (MVTec, 2000), que decompõe cada imagem nos três componentes de cores do sistema RGB (*Red* = vermelho, *Green* = verde e *Blue* = azul). Cada imagem de entrada gerou três arquivos textos, um para cada componente da imagem (RGB), contendo a distribuição de freqüência da intensidade dos níveis de cinza (256 níveis). Para edição da base geral de dados, juntaram-se os três arquivos textos de cada amostra, adicionando a classe a que a amostra pertencia. Assim, cada imagem passou a ter 769 ( $3 \cdot 256 + 1$ ) variáveis para representá-la, ou seja, a freqüência de cada nível de cinza para cada um dos componentes de cores RGB, representado as 768 variáveis de entrada e, também, uma variável de saída representando a classe de cada imagem ou exemplo.

A terceira fase da metodologia, referente à seleção de atributos, consistiu na aplicação de uma técnica multivariada para a seleção de variáveis quanto ao grau de importância na classificação dos sintomas, visando diminuir o número expressivo de variáveis de entrada e, assim, facilitar computacionalmente o treinamento das Redes Neurais Artificiais (RNA) na fase de categorização das imagens. Para isto, utilizou-se a técnica multivariada de dados expressa na análise de componentes principais (ACP) que permite a redução substancial do espaço paramétrico, praticamente, sem prejuízo da informação biológica contida na variabilidade das respostas (HOTTELING, 1936; JOHNSON; WICHERN, 2002). A ferramenta selecionada para aplicação da ACP foi a Weka (WITTEN; FRANK, 1999). A Weka é uma ferramenta para Aprendizado de Máquina (MITCHELL, 1997) desenvolvida na Universidade de Waikato, na Nova Zelândia, escrita em linguagem JAVA, com código aberto, que permite alterações nas funções a serem utilizadas, bem como a



inserção de implementações não suportadas. A operacionalização da Weka é de domínio público disponível no endereço eletrônico: <http://www.cs.waikato.ac.nz./ml/weka>.

Por último, finalizando o modelo proposto, aconteceu a etapa de classificação. Nesta etapa, utilizou-se a técnica de RNA para classificação dos referidos padrões coletados. Foram utilizadas RNAs *Perceptron* multicamadas, treinadas com o algoritmo *backpropagation* com termo *momentum* (HAYKIN, 1999) adotando-se como taxa de aprendizado e termo *momentum* os valores iguais a 0,2 e 0,3, respectivamente. A taxa de aprendizado representa a aceleração do aprendizado, ou seja, controla a velocidade de atualização dos pesos. Por sua vez, o termo *momentum* é uma constante que ajuda na atualização dos pesos, de maneira a contribuir para não se estacionar em mínimos locais. Nesta fase de classificação, também se utilizou a ferramenta Weka.

Toda a execução da experimentação computacional foi realizada em um microcomputador Intel Pentium 4 3,06 GHz, com 2 Gbytes de memória RAM e 200 Gbytes de memória auxiliar.

Continuando o procedimento operacional, para verificar a validação (consistência) do modelo proposto, foram utilizados alguns procedimentos e técnicas convencionais de confiabilidade. No caso de tarefas de classificação, uma medida comumente utilizada é a frequência (taxa) de erro do classificador  $h$ , também conhecida como probabilidade (taxa) de classificação incorreta ou errônea. A probabilidade clássica do erro é obtida utilizando a expressão  $e(h) = \frac{1}{n} \sum_{i=1}^n (y_i \neq f(x_i))$ , a qual acumula as discordâncias entre a classe original de cada amostra com o rótulo atribuído pelo classificador induzido ponderada pelo total de amostras. Utilizando a função indicadora, tem-se que se a indicação de classificação for concordante, há uma classificação correta, ou seja, expressão lógica verdadeira e, neste caso, o contador indica o valor 1, caso contrário, expressão lógica falsa, e o valor indicado consiste de 0. O procedimento é obtido repetido para todas as amostras e o operador matemático vai acumulando o resultado até o número  $n$  de unidades amostrais. O complemento da probabilidade de erro é tomado como a precisão do classificador (BARANAUSKAS, 2000).

Para obter uma estimativa não viciada de erro do classificador, utilizou-se de técnicas de amostragem para manipulação dos conjuntos de treinamento e teste. Neste

trabalho, considerou-se a metodologia *r-fold cross-validation* (EFRON; GONG, 1983; EFRON; TIBSHIRANI, 1993), que divide fraciona o conjunto de dados total, de tamanho  $n$ , em  $r$  partes mutuamente exclusivas (*folds*) de tamanhos iguais a  $n/r$  amostras. As amostras nos  $(r - 1)$  *folds* são usadas para treinamento e a hipótese induzida é testada no *fold* remanescente. Este processo é repetido  $r$  vezes, cada vez considerando um *fold* diferente para teste. O erro no *cross-validation* é a média dos erros calculados em cada um dos  $r$  *folds* de teste (BARANAUSKAS, 2000).

Para melhor entendimento do modelo proposto, a Figura 5 apresenta um diagrama em blocos com um resumo das etapas desenvolvidas no trabalho.

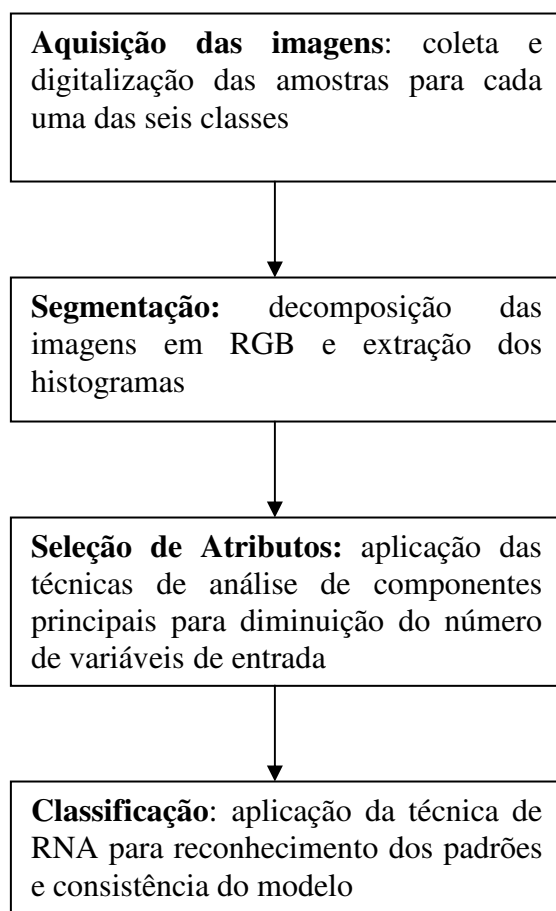


Figura 5. Diagrama das etapas desenvolvidas no trabalho.

#### 4. RESULTADOS E DISCUSSÃO

As distribuições de freqüências das intensidades dos 256 níveis de cinza para cada uma das três imagens decompostas foram estabelecidas por meio da ferramenta computacional construída para essa finalidade. Para cada arquivo de imagem “.jpeg”, representando as amostras, realizou-se a segmentação, decompondo essa imagem de entrada nos três componentes do sistema RGB e gerando um arquivo texto de saída contendo a distribuição de freqüências das intensidades dos níveis de cinza das componentes de imagens das 100 amostras. A Figura 6 ilustra a segmentação de uma amostra da classe Sadia realizada pela ferramenta desenvolvida.



Figura 6. Segmentação da imagem de uma amostra da classe Sadia.

O resultado da seleção dos atributos, após a segmentação de imagens, realizada pelas componentes principais a partir da matriz de correlação dos dados, está apresentado no Apêndice 1. Com a aplicação do critério de Kaiser, descartaram-se as combinações lineares das variáveis representadas nas componentes principais que possuíam

pequena variância (autovalor  $< 1$ ), restando 11 selecionadas. Essas primeiras componentes principais explicam acumuladamente 95% da variação total. Nessa Tabela do Apêndice 1, encontram-se, nas colunas, os autovetores relativos às componentes principais, cujos coeficientes representam os pesos de cada variável de entrada na obtenção das funções lineares. Na coluna *Nível de Cinza*, ilustra-se também entre parênteses a variável de entrada especificada (a). Algumas variáveis de entrada não foram indicadas por apresentarem nos valores dos coeficientes uma precisão inferior a  $10^{-4}$  e fornecerem pouca informação biológica.

Na Tabela 1, estão apresentados os autovalores e as porcentagens de variação explicada e acumulada em cada componente principal, mostrando que a porcentagem de variação explicada foi diminuindo a cada componente principal e que a variação acumulada nas 11 componentes resultava aproximadamente 96%. Essa porcentagem alcançada mostra-se bastante expressiva e é superior à relatada em diversos trabalhos consultados. Com a aplicação de ACP, Silva et al. (2002), Andrade et al. (2003), Freire Filho et al. (2003), Monteiro e Pinheiro (2004), explicaram, respectivamente, 78,6%, 79,00%, 61,25% e 72,22% da variação total. Heinem e Osório (2004) utilizam ACP para redução de variáveis de entrada de RNA aplicadas à autenticação de assinaturas manuscritas e obtêm uma redução de 115 para 38 variáveis de entrada, com 60% da variação total explicada. Em nosso estudo, para se ter um valor de porcentagem acumulada nos padrões das apresentadas, 5 componentes principais seriam suficientes (82,05%). Porém, como foi estabelecido um princípio para determinar o número de componentes, o critério do autovalor maior que um, o treinamento foi realizado com as 11 componentes.

Tabela 1. Autovalores e porcentagens de variação explicada e acumulada em cada componente principal.

Autovalor	190,71	102,39	83,99	56,26	49,08	26,34	22,91	11,79	8,60	6,32	4,82
%Variância Explicada	32,43	17,41	14,29	9,57	8,35	4,48	3,90	2,01	1,46	1,08	0,82
%Variância Acumulada	32,43	49,84	64,13	73,70	82,05	86,53	90,43	92,44	93,90	94,98	95,80

Usando as componentes principais apresentadas no Apêndice 1, o vetor para a fase de classificação foi composto por 11 variáveis de entrada e uma variável de saída representando a classe de uma determinada amostra. Realizou-se, então, o treinamento

da RNA *Perceptron* multicamadas. A Figura 7 exibe a arquitetura da RNA utilizada na classificação do experimento. Os traços gráficos em verde ilustram os neurônios da camada de entrada (componentes principais), os em vermelho, os neurônios da camada escondida e os amarelos, os neurônios da camada de saída, que são as classes.




Figura 7. Rede Neural Multicamadas utilizada no treinamento dos padrões do experimento.

A Tabela 2 destaca os resultados da classificação das 10 amostras dos 10 conjuntos de teste utilizados no modelo de classificação. A primeira coluna indica o conjunto de teste, a segunda, a amostra, a terceira, o rótulo original, a quarta, a predição realizada e, a última coluna, a classificação e quando assinalada com o sinal +, manifesta erro de alocação, ou seja, a indicação predita não coincide com a origem da amostra.

Tabela 2. Resultados da classificação dos conjuntos de teste.  
continua

<b>Conjunto</b>	<b>Amostra</b>	<b>Origem</b>	<b>Predito</b>	<b>Classificação</b>
1	1	três	três	Correta
1	2	três	dois	(+) Incorreta
1	3	dois	dois	Correta
1	4	dois	três	(+) Incorreta
1	5	óleo	três	(+) Incorreta
1	6	óleo	óleo	Correta
1	7	sadia	sadia	Correta
1	8	sadia	sadia	Correta
1	9	um	um	Correta
1	10	um	um	Correta
2	1	três	óleo	(+) Incorreta
2	2	três	três	Correta
2	3	dois	dois	Correta
2	4	dois	dois	Correta
2	5	óleo	três	(+) Incorreta
2	6	óleo	óleo	Correta
2	7	sadia	sadia	Correta
2	8	sadia	sadia	Correta
2	9	um	um	Correta
2	10	um	sadia	(+) Incorreta
3	1	três	três	Correta
3	2	três	três	Correta
3	3	dois	dois	Correta
3	4	dois	dois	Correta
3	5	óleo	óleo	Correta
3	6	óleo	óleo	Correta
3	7	sadia	sadia	Correta
3	8	sadia	sadia	Correta
3	9	um	um	Correta
3	10	um	um	Correta
4	1	três	três	Correta
4	2	três	três	Correta
4	3	dois	dois	Correta
4	4	dois	dois	Correta

continuação

<b>Conjunto</b>	<b>Amostra</b>	<b>Origem</b>	<b>Predito</b>	<b>Classificação</b>
4	5	óleo	óleo	Correta
4	6	óleo	óleo	Correta
4	7	sadia	sadia	Correta
4	8	sadia	sadia	Correta
4	9	um	um	Correta
4	10	um	um	Correta
5	1	três	óleo	(+) Incorreta
5	2	três	três	Correta
5	3	dois	dois	Correta
5	4	dois	dois	Correta
5	5	óleo	óleo	Correta
5	6	óleo	óleo	Correta
5	7	sadia	sadia	Correta
5	8	sadia	um	(+) Incorreta
5	9	um	um	Correta
5	10	um	um	Correta
6	1	três	três	Correta
6	2	três	três	Correta
6	3	dois	dois	Correta
6	4	dois	um	(+) Incorreta
6	5	óleo	óleo	Correta
6	6	óleo	óleo	Correta
6	7	sadia	sadia	Correta
6	8	sadia	um	(+) Incorreta
6	9	um	um	Correta
6	10	um	um	Correta
7	1	três	três	Correta
7	2	três	dois	(+) Incorreta
7	3	dois	dois	Correta
7	4	dois	um	(+) Incorreta
7	5	óleo	óleo	Correta
7	6	óleo	dois	(+) Incorreta
7	7	sadia	três	(+) Incorreta
7	8	sadia	sadia	Correta
7	9	um	um	Correta
7	10	um	um	Correta
8	1	três	três	Correta
8	2	três	óleo	(+) Incorreta
8	3	dois	dois	Correta
8	4	dois	dois	Correta
8	5	óleo	óleo	Correta
8	6	óleo	óleo	Correta
8	7	sadia	sadia	Correta
8	8	sadia	um	(+) Incorreta

conclusão				
Conjunto	Amostra	Origem	Predito	Classificação
8	9	um	um	Correta
8	10	um	um	Correta
9	1	três	três	Correta
9	2	três	três	Correta
9	3	dois	dois	Correta
9	4	dois	dois	Correta
9	5	óleo	óleo	Correta
9	6	óleo	óleo	Correta
9	7	sadia	sadia	Correta
9	8	sadia	sadia	Correta
9	9	um	um	Correta
9	10	um	um	Correta
10	1	três	dois	(+) Incorreta
10	2	três	três	Correta
10	3	dois	dois	Correta
10	4	dois	dois	Correta
10	5	óleo	três	(+) Incorreta
10	6	óleo	três	(+) Incorreta
10	7	sadia	sadia	Correta
10	8	um	um	Correta
10	9	um	um	Correta
10	10	sadia	sadia	Correta

A partir da Tabela 2 construiu-se a Tabela 3, que indica as frequências de classificação correta e incorreta de cada teste realizado no treinamento.

Tabela 3. Distribuição das classificações segundo os testes.

Teste (Conjunto)	Classificação		Total
	Correta	Incorreta	
1	7	3 (0,30)	10
2	7	3 (0,30)	10
3	10	0 (0,00)	10
4	10	0 (0,00)	10
5	8	2 (0,20)	10
6	8	2 (0,20)	10
7	6	4 (0,40)	10
8	8	2 (0,20)	10
9	10	0 (0,00)	10
10	7	3 (0,30)	10
<b>Total</b>	81	19	100



De acordo com o valor do erro médio ( $19,00\% \pm 14,49\%$ ) obtido a partir dos conjuntos de testes do classificador utilizado, nota-se um excelente desempenho do modelo proposto, cujo intervalo de 95% de confiança para o erro médio indica limites para a porcentagem de classificação média incorreta entre 8,63% e 29,54%.

O Quadro 2 ilustra a matriz de confusão dos conjuntos de teste e o resultado de classificação da RNA para o experimento.

Quadro 2. Matriz de confusão do resultado de classificação do experimento.

Destino Origem	Estádio 1	Estádio 2	Estádio 3	Sadia	Óleo	Total
Estádio 1	19 (95%)	0	0	1	0	20
Estádio 2	2	17 (85%)	1	0	0	20
Estádio 3	0	3	14 (70%)	0	3	20
Sadia	3	0	1	16 (80%)	0	20
Óleo	0	1	4	0	15 (75%)	20
Total	24	21	20	17	18	100

Em relação à homogeneidade das concordâncias de classificação entre as classes estudadas (Tabela 4 e Figura 8), verificou-se pelo resultado do teste não-paramétrico Qui-Quadrado que não foi possível mostrar diferença estaticamente significativa ( $P > 0,05$ ) entre elas. Também, considerando as concordâncias quanto à presença ou não da doença (Tabela 4 e Figura 9), não se verificou diferença estatística ( $P > 0,05$ ).

Tabela 4. Frequência de concordância entre origem e classificação pelo modelo proposto.

Classe de Severidade	Concordância		IC (Discordância)
	Ausente	Presente	
Estádio 1	1 (0,050)	19	(0,0%; 14,6%)
Estádio 2	3 (0,150)	17	(0,0%; 30,7%)
Estádio 3	6 (0,300)	14	(9,9% ; 50,1%)
Sadia	4 (0,200)	16	(2,5%; 37,5%)
Óleo	5 (0,250)	15	(6,0%; 44,0%)
Total	19 (0,190)	81	(11,3%; 26,7%)
Ausência da Doença	9 (0,225)	31	(9,6%; 35,4%)
Presença da Doença	10 (0,167)	50	(7,3%; 26,1%)

Na Tabela 5 está disposto o teste de diagnóstico do modelo, mostrando que, de acordo com os valores de sensibilidade ( $a/(a+c)$ ), 0,93 e especificidade ( $d/(b+d)$ ), 0,78, o modelo é altamente eficiente na identificação da doença (sensibilidade) e mais reduzido na identificação da ausência da doença (especificidade).

Tabela 5. Teste de Diagnóstico do modelo proposto.

Resultado do Teste	População		Total
	Infectados	Normais	
Positivo	a (56)	b (9)	a + b (65)
Negativo	c (4)	d (31)	c + d (35)
Total	a + c (60)	b + d (40)	n(100)




Figura 8. Porcentagem de concordância ausente média dos conjuntos de teste com intervalo de confiança para as classes.




Figura 9. Porcentagem de concordância ausente média dos conjuntos de teste com intervalo de confiança para ausência e presença da doença.

Os resultados apresentados pelas porcentagens de classificação incorreta e homogeneidade de concordâncias entre as classes estudadas na Sigatoka Negra evidenciam o bom desempenho do modelo proposto quanto à identificação da doença e dos seus respectivos estádios, mostrando que é possível o monitoramento da enfermidade com uma taxa errônea relativamente baixa.

## 5. CONCLUSÕES

Os resultados encontrados na presente pesquisa remetem às seguintes considerações.

1. A análise de componentes principais descartou combinações lineares das variáveis de entrada que possuíam pequenas variâncias e preservou aquelas que possuíam as maiores variâncias. Esse fato tornou possível o treinamento das redes neurais com a diminuição das variáveis de entrada de maneira substancial, representando uma redução de 98,6%.

2. A combinação de Componentes Principais com Redes Neurais Artificiais, sendo a primeira técnica utilizada na seleção de atributos e, a segunda, na fase de classificação, se complementaram para robustecer a validação do modelo proposto

3. As maiores frequências de acertos do modelo foram para as classes que mais interessam ao monitoramento, mostrando a robustez do classificador gerado, evidenciada pela baixa probabilidade de classificação incorreta.

4. Os valores da sensibilidade e especificidade mostraram que o modelo é altamente eficiente na identificação da doença (sensibilidade) e mais reduzido na identificação da ausência da doença (especificidade).

5. O modelo proposto mostra-se promissor no que diz respeito a fornecer conhecimento para um sistema automático de monitoramento. Esse sistema poderá ser instalado em um dispositivo eletrônico que detectará a doença, transferindo as informações

do monitoramento automaticamente. O dispositivo poderá ser implementado com baixo custo, tornando-se acessível não só a grandes, mas também a pequenos e médios produtores, de maneira a evidenciar a importância destacada pela aplicação prática deste trabalho e se tornando um importante instrumento no combate da Sigatoka Negra.

## 6. REFERÊNCIAS BIBLIOGRÁFICAS

AGUIAR, N. A. O.; OLIVEIRA, S. H. A.; THOMAZ, C. E. Análise Estatística Multivariada de Imagens Cerebrais de Controles e Pacientes com Alzheimer e Transtorno Obsessivo Compulsivo. In: **Anais do XXVIII Congresso da Sociedade Brasileira de Computação**, Belém do Pará, Brasil, FEI, 2008. p. 41 – 49.

AGUIRRE, G. M. C.; CASTAÑO-ZAPATA, J. & ZULUAGA, L. E. Método rápido de diagnóstico de *Mycosphaerella musicola* Leach y *M. fijiensis* Morelet, agentes causantes de las sigatokas amarilla y negra. **Rev. Acad. Colomb. Cienc**, Bogotá, v.27, n.105: p. 619-623. 2003.

ANDERSON, T. W. Asymptotic theory for principal components analysis, **Annals of Mathematical Statistics**, Ann Arbor, v. 34: p. 122 – 148, 1963.

ANDERSON, T. W. **An introduction to multivariate statistical analysis**, New York: John Willey, 1984.

ANDRADE, J. B.; JUNIOR, E. F.; POSSENTI, R. A.; OTSUK, I. P.; ZIMBACK, L.; LANDELL, M. G. DE A. Seleção de 39 variedades de cana-de-açúcar para alimentação animal. **Brazilian Journal of Veterinary Research and Animal Science**, São Paulo, SP, v. 40, p. 287 – 296, 2003.

BAESSO, M. M.; PINTO, F. DE A. DE C.; QUEIROZ, D. M.; VIEIRA, L. B.; ALVES, E. A. Determinação do “status” nutricional de nitrogênio no feijoeiro utilizando imagens digitais coloridas. **Engenharia Agrícola**, Jaboticabal, v.27, n.2, p.520 – 528, maio/ago. 2007

BARANAUSKAS, J. A. **Extração automática de conhecimento por múltiplos indutores**. Tese de Doutorado: Instituto de Ciências Matemáticas e de Computação, USP, 2000.

BRAGA, A. P.; CARVALHO, A. C. P. F.; LUDERMIR, E T. B. **Redes Neurais Artificiais: teoria e aplicações**. Rio de Janeiro: Livro Técnico e Científico, 2000.

BREIMAN, L. Bagging Predictors. **Machine Learning**, v. 24, n. 2: p. 123-140, 1996.

Coordenadoria de Defesa Agropecuária. **Sistema de mitigação de risco para a Sigatoka Negra na cultura da banana**. Disponível em: <[http://www.cda.sp.gov.br/www/servicos/transito\\_smr.php](http://www.cda.sp.gov.br/www/servicos/transito_smr.php)>. Acesso em: 20 set. 2007.

BURKS, T. F.; SHEARER, S. A.; HEATH, J. R.; DONOHUE, K. D.; Evaluation of neural-network classifiers for weed species discrimination. **Biosyst Eng**, Kidlington, v. 91, n. 3: p. 293–304. 2005.

CHAKRABORTY, S. Anthracnose disease of *Stylosanthes*. In: CHAKRABORTY, S. (Ed.). **High-yielding anthracnose-resistant *Stylosanthes* for agricultural systems**. Canberra: Aciar, p.113-124, 2004.

COELHO FILHO, M.A.; ANGELOCCI, L.R.; VASCONCELOS, M.R.B.; COELHO, E. F. Estimativa da área foliar de plantas de lima ácida 'Tahiti' usando métodos não-destrutivos. **Revista Brasileira de Fruticultura**, Jaboticabal, v. 27, n. 1: p. 163 – 167, 2005.

CORKIDI, G.; BALDERAS-RUIZ, K.A.; TABOADA, B.; SERRANO-CARREÓN, L.; GALINDO, E. Assessing mango anthracnose using a new three-dimensional image-analysis technique to quantify lesions on fruit. **Plant Pathology**, Oxford, UK, v. 55, n. 2: p. 250-257, 2006.

CRUVINEL, P. E.. Eletronic as an important tool for modern agriculture and the experience of the nucleus of research and development of agricultural instrumentation. CNPDIA, (EMBRAPA). In: **II Escuela Latino americana de Física de Suelos**, Buenos Aires, Argentina, 1992.

CRUVINEL, P. E.; MINATEL, E.R.; MUCHERONI, M.L.; VIEIRA, S.R.; CRESTANA, S. An automatic method base don image processing for measurements of drop size distribution from agricultural sprinklers: In: **Simpósio Brasileiro de Computação Gráfica e Processamento de Imagens**, 9., Caxambu, MG, Anais...Caxambu, MG: SBC; Belo Horizonte: UFMG, 1996, p. 39-46.

CRUZ, E. S.; CARVALHO, D. F.; VARELLA, C. A. A.; SILVA, L. D. B.; SOUZA, W. J.; PINTO, F. A. C. Comparação de classificadores de imagens digitais na determinação da cobertura do solo. **Engenharia Agrícola. Agríc.**, Jaboticabal, v.28, n.2, p. 237 – 244, abr./jun, 2008.

CYBENKO, G. Neural Networks in Computational Science and Engineering, **Institute of Electrical and Electronics Engineers: Computational Science & Engineering**, Spring, p. 36 – 43, 1996.



DONOHUE, K. D.; HUANG, L.; BURKS, T.; FORSBERG, F.; PICOLLI, C. W. Tissue classification with generalized spectrum parameters. **Ultrasound Med. Biol.**, v. 27, n. 11: p. 1505–1514. Summary Plus, 2001.

EFRON, B.; GONG, G. A leisurely Look at the bootstrap, the jackknife, and crossvalidation. **The American Statistician**, Washington, DC, v.37, n.1, p.36-48. 983.

EFRON, B.; TIBSHIRANI, R. J. **An Introduction to the Bootstrap**. New York: Chapman & Hall, 1993.

FAO STAT AGRICULTURE DADA. Disponível em: <http://apps.fao.org/> . Acesso em 20 de abr. 2005.

FERRARI, J. T.; NOGUEIRA, E. M. de C. **Situação e dispersão da Sigatoka Negra da bananeira no Estado de São Paulo**. Disponível em: <[http://www.biologico.sp.gov.br/artigos\\_tecnicos/dispersao\\_sigatoka.htm](http://www.biologico.sp.gov.br/artigos_tecnicos/dispersao_sigatoka.htm)>. Acesso em: 20 set. 2007.

FERRARI, J. T.; NOGUEIRA, E. M. C; GASPAROTTO, L.; HANADA, R. E.; LOUZEIRO, L. M. **Ocorrência da Sigatoka-negra em bananais no Estado de São Paulo**. Arquivos do Instituto Biológico, v. 72: p. 133 – 134, 2005.

FERRARI, J. T.; NOGUEIRA, E. M. de C.; GASPAROTTO, L.; HANADA, R. E. Ocorrência de Sigatoka Negra no Estado de São Paulo. **Summa Phytopathologica** 31 (Supl.): 33. 2005b Resumo.

FERRARI, J. T.; NOGUEIRA, E. M. DE C. Como Identificar e Combater a Sigatoka Negra da Bananeira. São Paulo: Instituto Biológico. **Fitopatologia Brasileira**, Brasília, DF, v. 28: p. 656-663. Disponível em: <<http://www.biologico.sp.gov.br/>>. Acesso em: mar. 2005.

FOURÉ, E. Stratégies de lutte contre la Cercospora noire des bananiers et des plantains provoqué par *Mycosphaerella fijiensis* Morelet. L'avertissement biologique au Cameroun. Evaluation des possibilités de amélioration. **Fruits**, Paris, v. 43, n. 5: p. 269 – 274. 1988.

FREIRE FILHO, F. R.; RIBEIRO, V. Q.; ROCHA, M. DE M.; LOPES, A. C. DE A. Adaptabilidade e estabilidade da produtividade de grãos de genótipos de caupi enramador de tegumento mulato. **Pesquisa Agropecuária Brasileira**, Brasília, DF, v. 38, n. 5, p. 591 – 598, maio 2003.

GANRY, J.; MEYER, J. P. La lutte controlée contre le cercospora aux Antilles. Bases climatiques de l'avertissement. Technique d'observation et numération de la maladie. **Fruits**, Paris, v.27, n. 11: p. 767 – 774, 1972.

GASPAROTTO, L.; PEREIRA, J. C. R.; HANADA, R. E.; MONTARROYOS, A. V. V. **Sigatoka-negra da bananeira**. Manaus: EMBRAPA Amazônia Ocidental, 2006.

GELMINI, G. A. **Controle da Sigatoka Negra na Cultura da Banana: indicações básicas**. Campinas: Coordenadoria de Defesa Agropecuária, 2004. 32p. (Manual, 2).

GOMES, J.; VELHO, L. **Computação Gráfica: Imagem**. Rio de Janeiro: IMPA/SBM, 1994.

GOMES FILHO, A.; OLIVEIRA, J.G.; VIANA, A.P.; DAMASCENO JÚNIOR, P. C.; PEREIRA, M.G. Validação do método das notas para quantificação da incidência da mancha fisiológica do mamão através do uso de imagens digitais. **Revista Brasileira de Fruticultura**, Jaboticabal, v. 28, n. 3: p. 365 – 368, 2006.

GOMEZ, A. H.; WANG, J.; HU, G. X.; PEREIRA, A. G. Electronic nose technique potential monitoring mandarin maturity, **Sens. Actuators B: Chemical**, v. 113, n. 1: p. 347 – 353, 2006.

GONÇALVES, J. S.; PEREZ, L. H.; SOUZA, S. A. M. Perspectiva econômica da banana não é negra e futuro indica: Siga a modernidade e Toca inovação. In: **I Simpósio de Manejo Adequado da Sigatoka Negra na Cultura da Banana**. In: **XIII Reunião Itinerante de Fitossanidade do Instituto Biológico: A Cultura da Banana**, Pariquera-Açú, SP: Instituto Biológico; APTA Regional, 2006, p.109 – 124.

GONZÁLES, M. Metodología para la manipulación y cultivo in vitro de *Mycosphaerella fijiensis*. **Manejo Integrado de Plagas**, Turrialba, v.53: i-iv, 1999.

GRANITTO, P.M.; VERDES, P.F.; CECCATTO, H.A. Large-scale investigation of weed seed identification by machine vision. **Computers and electronics in agriculture**, v. 47: p. 15 – 24, 2005.

GROSSBERG, S.; MINGOLLA, E. Neural dynamics of surface perception Boundary webs illuminants and shape-from-shading. **Computer Vision Graphics and Image Processing**, San Diego, EUA, v. 37: 116 – 165, 1987.

HAHN, F.; LOPEZ, I.; HERNANDEZ, G. 2004. Spectral detection and Neural Network discrimination of *Rhizopus Stolonifer* Spores on red tomatoes. **Biosystems Eng.**, Silsoe, UK, v. 89: p. 93 – 99.

HANADA, R. E.; GASPAROTTO, L.; PEREIRA, J. C. R. Esporulação de *Mycosphaerella fijiensis* em diferentes meios de cultura. **Fitopatologia Brasileira**, Brasília, v.27, n.2: p. 170 – 173, 2002.

HAYKIN, S. **Neural Networks: A Comprehensive Foundation**. New York, US: MacMillan, 1999.

HEBB, D. O. **The organization of Behavior**. New York: Willey, 1949.

HENDERSONA, J.; PATTEMOREA, J. A.; PORCHUNA, S. C.; HAYDENB, H. L.; VAN

BRUNSCHOTA, S.; GRICEC, K. R. E.; PETERSONC, R. A.; THOMAS-HALLD, S. R.; AITKEND, E. A. B. Black Sigatoka disease: new technologies to strengthen eradication strategies in Australia. **Australasian Plant Pathology**, v. 35: p. 181 – 193, 2006.

HOPFIELD, J. J. Neural Networks and Physical Systems with Emergent Collective Computational Abilities, **Proc. Nat. Acad. Science**, Cambridge, USA, v. 79: 2554-2558, 1982.

HOTELLING, H. Analysis of a complex statistical variables into principal components. **J. Educ. Psychol.** Arlington, US. vol. 24: p. 417 – 441, 1933.

HOTELLING, H. Simplified calculation of principal components. **Psychometrika**, Williamsburg, US. v.1: 27-35, 1936.

HWANG, H.; PARK, B.; NGUYEN, M.; CHEN, Y. Hybrid image processing for robust extraction of lean tissue on beef cut surfaces. **Computers and electronics in agriculture**, New York, US. v. 17, n.3: p. 281 – 294, 1997.

HUANG, K. Application of artificial neural network for detecting Phalaenopsis seedling diseases using color and texture features. **Computers and electronics in agriculture**, New York, US. v. 57, n.1: p. 3 – 11, 2007.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA – Sistema IBGE de Recuperação Automática - SIDRA. **Banco de Dados agregados: Produção agrícola municipal**. Disponível em: <http://www.sidra.ibge.gov.br/bda/...>. Acesso em: 20 abr. 2005.

IRISH, B. M.; GOENAGA, R.; PLOETZ, R. C. *Mycosphaerella fijiensis*, Causal Agent of Black Sigatoka of *Musa* spp. Found in Puerto Rico and Identified by Polymerase Chain Reaction. **Plant Disease**, Saint Paul, US, v. 90: p. 684, 2006.

JOHANSON, A. Detection of banana leaf spot pathogens by PCR. **OEPP/EPPO Bulletin**, v. 25: p. 99 – 107, 1995.

JOHNSON, R.A.; WICHERN, D.W. **Applied Multivariate Statistical Analysis**, 5 ed., New Jersey: Prentice-Hall, 2002, 767p.

KAVDIR, I.; GUYER, D. E. Comparison of artificial neural networks and statistical classifiers in apple sorting using textural features, **Biosystems Engineering**, London, UK, v.89, n.3: p. 331 – 344, 2004.

KOHONEN, T. Self-organized formation of topologically correct feature maps. **Biological Cybernetics**, New York, US, v. 43: p. 59 – 69, 1982.

LITTEL, R. C; PEBDERGAST, J.; NATARAJAN, R. Modelling covariance structure in the analysis of repeated measures data. **Statistics in Medicine**, New York, US, v.19: p. 1793 – 1819, 2000.

LUPETTI, K.O.; CARVALHO, L.C.; MOURA, A.F.; FATIBELLOFILHO, O. Análise de imagem em química analítica: Empregando metodologias simples e didáticas para entender e prevenir o escurecimento de tecidos vegetais. **Quim. Nova**, São Paulo, SP, v.28, n.3: p.548 – 554, 2005.

MAPA. Agricultura Brasileira em Números: Anuário 2005. Disponível em: <[http://www.agricultura.gov.br/pls/portal/docs/page/mapa/estatisticas/agricultura\\_em\\_numero\\_s](http://www.agricultura.gov.br/pls/portal/docs/page/mapa/estatisticas/agricultura_em_numero_s)>. Acesso em: 20 set. 2007.

MARCHANT, J.A. Tracking of row structure in three crops using image analysis. **Computers and electronics in agriculture**, New York, US, v.30, n.2: p.161 – 179, 1996.

MARDIA, K. V.; KENT, J; BIBBY, J. M. **Multivariate analysis**. London: Academic Press, 1997.

MARÍN, D. H.; ROMERO, R. A. **El Combate de la Sigatoka Negra**. Costa Rica: Corporación Bananeira Nacional, 1992. 20p. (Boletín, 4).

MARÍN, D. H.; ROMERO, R. A.; GUZMÁN, M.; SUTTON, T. B. Black Sigatoka: An Increasing Threat to Banana Cultivation. **Plant Disease**, Saint Paul, US, v. 87, n.3: p208 – 222, 2003.

MARRIOT, F. H. C. **The interpreation of multiple observations**. London: Academic Press, 1974.

McCULLOCH, W. S.; PITTS, W. A Logical Calculus of the Ideas Immanent in Nervous Activity. **Bulletin of Mathematical Biophysics**, New York, US, v.5: p.115 – 133, 1943.

MERCHÁN, V. M.; CHAVARRIAGA, W. M. Alternativas de manejo de sigatoka negra en plátano Hartón (Musa AAB). In: **Memorias de la XI Reunión ACORBAT**. San José, Costa Rica, 1994, p. 325 – 335.

MESSETI, A. V. L. **Utilização de técnicas multivariadas na avaliação da divergência genética de populações de girassol (*Helianthus annuus*, L.)**. Tese de Doutorado: Energia na Agricultura, FCA, 2007. 87p.

MICHEREFF, S. J.; NORONHA, M. A.; ROCHA JÚNIOR, O. M.; SILVA, J. A.; MIZUBUTI, E. S. G. Variabilidade de isolados de *Alternaria brassicicola* no estado de Pernambuco. **Fitopatologia Brasileira**, Brasília, v. 28: p. 656 – 663, 2003.

MINSKY, M.; PAPERT, S. **Perceptrons**. Cambridge, MA: MIT Press, 1969.

MITCHELL, T. M. **Machine learning**. Boston: McGraw Hill Companies Inc., 1997, 414p.

MODENESE, S. H. **Algoritmo para recomendação de nutrientes agrícolas baseado em**

**técnicas do processamento digital de sinais e imagens.** Dissertação de Mestrado: Universidade Federal de São Carlos, 1998.

MONTEIRO, V. P.; PINHEIRO, J. C. V. Critério para implantação de tecnologias de suprimentos de água potável em municípios cearenses afetados pelo alto teor de sal. **Revista de Economia e Sociologia Rural**, Brasília, DF, v. 42, n. 2, p. 365 – 387, abr./jun. 2004.

MORAES, W. da S., ALVES, S. A. M., FUZITANI, E. J., SILVA, C. M. Manejo integrado da Sigatoka negra na cultura da banana. In: **Workshop sobre Inovações Tecnológicas em Bananicultura**, Botucatu, SP: Universidade Estadual Paulista, 2008.

MORAES, W. da S.; FUKUDA, E.; MENDONÇA, J. C. de.; SILVA, C. M. da.; MODONESE-GORLA DA SILVA, S. H. Behaviour of black Sigatoka in banana plantations of the Ribeira Valley, Sant Paul, Brazil. In: **Anais da XVII Reunião Internacional da Associação para a Cooperação em Pesquisas sobre Banana no Caribe e América Tropical (ACORBAT)**, Joinvile, SC, 2006, v.2: p. 656 – 661.

MORAES, W. da S.; FUKUDA, E.; MODONESE-GORLA DASILVA, S. H.; MENDONÇA, J. C.; LIMA, J. D. MENDES, C. DA S. Aplicativo para estimativa biológica da Sigatoka-negra (*Mycosphaerella fijiensis* Morelet). **Fitopatologia Brasileira**, Brasília, DF, v. 30 (Supl): p.193. 2005a. Resumo.

MORAES, W. da S.; MENDONÇA, J. C.; FUKUDA, E.; MENDES, C. DA S.; LIMA, J. D. SANTOS, A. J. dos. Dominância da Sigatoka-negra em bananais do Vale do Ribeira. **Fitopatologia Brasileira**, Brasília, DF, v. 30 (Supl.): p. 193. 2005b. Resumo.

MORAES, W. da S.; FUKUDA, E.; MENDONÇA, J. C. de.; SILVA, C. M. da.; MODONESE-GORLA DA SILVA, S. H. Behaviour of black Sigatoka in banana plantations of the Ribeira Valley, Sant Paul, Brazil. In: **Anais da XVII Reunião Internacional da Associação para a Cooperação em Pesquisas sobre Banana no Caribe e América Tropical (ACORBAT)**, Joinvile, SC, 2006, v.2: p. 656 – 661.

MOURICHON, X., PETER, D. & ZAPATER, M. Inoculation expérimentale de *Mycosphaerella fijiensis* Morelet sur de jeunes plantules de bananiers issues de culture in vitro. **Fruits**, Paris, FR, v. 4: p. 195 – 198, 1987.

MOYA, E.A.; BARRALES, L.R.; APABLAZA, G.E. Assessment of the disease severity of squash powdery mildew through visual analysis, digital image analysis and validation of these methodologies. **Crop Protection**, Guildford, UK, v.24: p. 785 – 789, 2005.

MVTec Software GmbH. MVTec Halcon. Germany, January, 2000.(<http://mvtec.com>).

NASCIMENTO, A. R. P., MARIANO, R. L. R. & VIANA, I. O. Meio semi-seletivo para isolamento de *Xanthomonas campestris* pv. *viticola*. **Ciência Rural**, Santa Maria, RS, v. 36: p. 1317 – 1320, 2006.

NÄÄS, I. A.; CAMPOS, L. S. L.; BARACHO, M. S.; TOLON, Y. B. Uso de redes neurais artificiais na identificação de vocalização de suínos. **Engenharia Agrícola**, Jaboticabal, v.28, n.2, p. 204 – 216, abr. / jun, 2008.

NEVATIA, R. Image segmentation. In: T.Y. Young and K.-S. Fu, Editors, **Handbook of Pattern Recognition and Image Processing**, Orlando: Academic Press, 1986.

NIBLACK, W. **An Introduction to digital image processing**. 2<sup>a</sup> ed, Prentice-Hall, 1986.

OROZCO-SANTOS, M. **Manejo Integrado de la Sigatoka Negra Del Plátan**. Mexico, DF: INIBAP, Folleto Técnico, v.1, 95 p., 1998.

PEREIRA, J. C. R.; GASPAROTTO, L.; COELHO, A. F. da S. & URBEN, A. F. Ocorrência da Sigatoka negra no Brasil. **Fitopatologia Brasileira**, Brasília, DF, v. 23 (Supl.): 295. 1998 (Resumos).

PEREIRA, J. C. R.; GASPAROTTO, L.; COELHO, A. F. S.; VÉRAS, S. DE M. **Doenças da Bananeira no Estado do Amazonas**. 3 ed. Manaus: Embrapa Amazônia Ocidental. (Circular Técnica, 20), 2001.

PÉREZ, L. V. Epidemiología de la Sigatoka Negra (*Mycosphaerella fijiensis* Morelet) em Cuba. II. Prognóstico Bio-Climático de los Plátanos de los Tratamientos contra la Enfermedad em Plátanos (*Musa* spp. AAB). **Revista Mexicana de Fitopatologia**, Obregón, México, v.18, n.1: p. 27 – 35. 2000a.

PÉREZ, L. V. Epidemiología de la Sigatoka Negra (*Mycosphaerella fijiensis* Morelet) em Cuba. I. Prognóstico Bio-Climático de los Plátanos de los Tratamientos de Fungicidas en Bananos (*Musa acuminata* AAA). **Revista Mexicana de Fitopatologia**, Obregón, México, v.18, n.1: p. 15 – 26. 2000b.

PÉREZ, L. V. **Manual para el Manejo Integrado de Sigatoka Negra (*Mycosphaerella fijiensis* Morelet) y Sigatoka Amarilla (*Mycosphaerella misicola* Leach ex Mulder) en Banano y Plátan**. Habana, Cuba: Instituto de Investigaciones de Sanidad Vegetal, 1996, 49p.

PERNOMIAN, V. A; DUARTE, F.V; ISAAC, F. Sistema automático de pulverização utilizando técnicas de processamento digital de imagens: **Revista científica eletrônica de agronomia**, n.5, 2004.

PICOLI, M. C. A. **Estimativa da produtividade agrícola da cana-de-açúcar utilizando agregados de redes neurais artificiais: estudo de caso da usina Catanduva**. Dissertação de Mestrado: Instituto Nacional de Pesquisas Espaciais (INPE), 2007.

PLUCKNETT, D. L.; WINKELMANN, D. L. **Technology for sustainable agriculture**. New York: Scientific American, US, p. 182 – 186, 1995.

POMPERMAYER NETO, P.; COUTO, H.T.Z. Utilização de imagens de videografia aérea na

detecção de deficiências nutricionais em plantios de eucalipto. **Scientia Forestalis**, Piracicaba, SP, n. 63: p. 23 – 31, jun. 2003.

PRATES, L. G.; FERNANDES, J. M. C. Avaliando a taxa de expansão de lesões de *Bipolaris sorokiniana* em trigo. **Fitopatologia Brasileira**, Brasília, DF, v. 26: p. 185 – 191, 2001.

PYDIPATI, R.; BURKS, T. F. AND W.S. LEE, Identification of citrus disease using color texture features and discriminant analysis, **Computers and Electronics in Agriculture**, New York, US, p. 49 – 59, 2006.

RENCHER, A. C. Interpretation of canonical discriminant functions, canonical variates and principal components. **American Statistician**, Washington, US, v. 46: p.217 – 225, 1992.

ROMERO, R.A.; SUTTON, T.B. Reaction of four *Musa* of three temperatures to isolates of *Mycosphaerella fijiensis* from different geographical regions. **Plant Disease**, Saint Paul, US, v. 10: p.1139 – 1142, 1997.

RUMELHART, D. E.; HINTON, G. E., WILLIAMS, R. J. Learning representations by back-propagation errors. **Nature**, London, UK, v. 323: p. 533 – 536, 1986.

ROSENBLATT, M. **Principles of neurodynamics: Perceptron and Theory of Brain Mechanisms**. Washington D.C.: Spartan-Books, 1962.

SANCHES, I. A.; GÜRTLER, S.; FORMAGGION, A. R. Discriminação de variedades de citros em imagens CCD/CBERS-2. **Ciência Rural**, Santa Maria, v.38, n.1, p. 103 – 108, jan - fev, 2008.

SANTOS, J.A.; JULIATTI, F.C.; SANTOS, V.A.; POLIZEL, A.C.; JULIATTI, F.C.; HAMAWAKI, O.T. Caracteres epidemiológicos e uso da análise de agrupamento para resistência parcial à ferrugem da soja. **Pesquisa Agropecuária Brasileira**, Brasília, DF, v. 42: p. 443 – 447, 2007.

SCHOENINGER, E. R. **Uso de redes neurais artificiais para mapeamento de biomassa e carbono orgânico no componente arbóreo de uma floresta ombrófila densa**. Tese de Doutorado: Programa de Pós-Graduação em Engenharia Florestal, UFPR, 2006.

SENA JUNIOR, D. G.; PINTO, F. A. C.; QUEIROZ, D. M. Algorithm for classification of fall armyworm (*Spodoptera frugiperda*, Smith) damaged corn plants on digital images. **Revista Brasileira de Engenharia Agrícola e Ambiental**, Campina Grande, PB, v. 5, n. 3: p. 502 – 509, 2001.

SENA JÚNIOR, D. G.; PINTO, F.A.C.; GOMIDE, L.A.; TEIXEIRA, M.M. Avaliação de métodos automáticos de limiarização para imagens de plantas de milho atacadas por *Spodoptera frugiperda*. **Revista Brasileira de Engenharia Agrícola e Ambiental**, Campina Grande, PB, v. 7, n. 2: p. 359 – 366, 2003.

SENA JUNIOR, D. G.; PINTO, F. DE A. DE C.; QUEIROZ, D. M.; ALVES, E. A.; MAGALHÃES, J. R. Influência do solo na identificação de doses de nitrogênio em trigo utilizando classificadores multivariados com base em imagens digitais. In: **Anais XIII Simpósio Brasileiro de Sensoriamento Remoto**, Florianópolis, Brasil, INPE, 2007, p. 385 – 392.

SHAPIRE, R.E. The strength of weak learnability. **Machine Learning**, Boston, US, v.5, n. 2: p. 197 – 227, 1990.

SILVA, F. V.; KAMOGAWA, M. Y.; FERREIRA, M. M. C.; NÓBREGA, J. A.; NOGUEIRA, A. R. A. Discriminação geográfica de águas minerais dos estado de São Paulo através da análise exploratória. **Ecletica Química**, Araraquara, SP, v. 27, n. spe, p. 91 – 102, 2002.

SILVA, N. R. **Aplicativo computacional para utilização de componentes principais em experimentação agrônômica**. Dissertação de Mestrado: Energia na Agricultura, FCA, 2005. 101p.

SILVA, N. R.; PADOVANI, C.R. Utilização de componentes principais em experimentação agrônômica. **Energia na Agricultura**, Botucatu, SP, v.21, n. 4: p. 98 – 113, 2006.

SIMEÃO, S. F. A. P. **Aplicativo computacional da função discriminante quadrática para utilização em Ciências Experimentais**. Tese de Doutorado: Energia na Agricultura, FCA, 2007. 143p.

SIMÕES, A. S.; COSTA, A. H. R. Classificação de Laranjas Baseada em Padrões Visuais. In: **6º Simpósio Brasileiro de Automação Inteligente (SBAI)**. Sociedade Brasileira de Automática. Bauru, setembro 14-17, p. 77 – 81, 2003.

SINGER, J. M; ANDRADE, D. F. Analysis of longitudinal data. In: **Handbook of Statistics**, v. 18; Bio-environmental and Public Health Statistics. Eds: P. K. Sen and C. R. Rao. Amsterdam: North Holland, p. 115 – 160, 2000.

SOARES, PEDRO L. M.; SANTOS, JAIME M. dos; FERRAUDO, ANTONIO S. Estudo morfométrico comparativo de 58 populações brasileiras de *Rotylenchulus reniformis* (*Nemata: Rotylenchulinae*). **Fitopatologia Brasileira**, Brasília, DF, v.29, n.4: p.419 – 424, 2004.

SODRÉ, G.S.; MARCHINI, L.C.; MORETI, A.C.C.; OTSUK, I.P.; CARVALHO, C.A.L. Caracterização físico-química de amostras de méis de *Apis mellifera* L. (Hymenoptera: Apidae) do Estado do Ceará. **Ciência Rural**, Santa Maria, RS, v. 37, n.4: p. 1139 – 1144, 2007.

SPÓSITO, M. B. **Dinâmica temporal e espacial da mancha preta (*Guignardia citricarpa*) e quantificação dos danos causados à cultura dos citros**. Tese de Doutorado: ESALQ - Universidade de São Paulo, Piracicaba, 2004.



TANSKA, M.; ROTKIEWICZ, D.; KOZIROK, W.; KONOPKA, I. Measurement of the geometrical features and surface color of rapeseeds using digital image analysis. **Food Res. Int.**, Barking, UK, v.38: p. 741 – 750, 2005.

TEIXEIRA, E. F.; CICERO, S. M.; NETO, D. D. Análise de imagens digitais na avaliação de plântulas de milho. **Revista Brasileira de Sementes**, Brasília, DF, v. 28, n. 2, p.159 – 167, 2006.

TEIXEIRA, E. F.; NETO, D. D.; CÍCERO, S. M.; MARTIN, T. N. Análise da uniformidade de sementes de milho via processamento de imagens digitais. **Revista da FZVA**, Uruguaiana, RS, v.14, n.1, p. 14 – 24, 2007.

TILLET, R.D; ONYANGO, C. M.; MARCHANT, J.A. Using model-based image processing to track animal movements. **Computers and electronics in agriculture**, New York, US, v. 17, n.2: p. 249 – 261, 1997.

VARELLA, C. A. A.; PINTO, F.A.C.; QUEIROZ, D. M.; SENA JÚNIOR, D.G., Determinação da cobertura do solo por análise de imagens e redes neurais **Revista Brasileira de Engenharia Agrícola e Ambiental**, Campina Grande, PB, v.6, n.2: p. 225 – 229, 2002.

WIDROW, B.; HOFF, M. E. Adaptative switching circuits. Institute of Radio Engineers. **Western Electronic Show and Convention**, 1960.

WITTEN, I.H.; FRANK, E. **Data Mining: Practical Machine Learning Tools and Techniques with Java Implementations**. Morgan Kaufmann, 1999.

YANG, C.C.; PRASHER S. O.; LANDRY J.A.; RAMASWAMY H.S.; DITOMMASO, A. Application of artificial neural networks in image recognition and classification of crop and weeds. **Canadian Agricultural Engineering**, Ottawa, CA, v.42, n.3: p. 147 – 152, 2000.

**APÊNDICE 1 - COEFICIENTES DAS COMPONENTES PRINCIPAIS E  
PORCENTAGEM DE EXPLICAÇÃO ACUMULADA DAS FUNÇÕES.**

Coeficientes das componentes principais e porcentagem de explicação acumulada das funções.

Sistema	Nível de Cinza	Componente Principal										
		V1	V2	V3	V4	V5	V6	V7	V8	V9	V10	V11
R	N55 (a56)	-0,0069	0,0035	-0,0014	0,0063	0,0052	-0,0059	0,0081	-0,0083	0,1251	0,0108	-0,2209
R	N59 (a60)	-0,0047	0,0014	-0,0054	0,0015	-0,0025	0,0066	0,0002	-0,0569	0,2803	0,0169	-0,0702
R	N62 (a63)	0,0019	-0,0064	-0,0007	-0,0109	-0,0150	0,0169	-0,0196	-0,0540	0,2668	-0,0258	0,1681
R	N63 (a64)	-0,0163	0,0380	0,0056	-0,0337	-0,0239	0,0310	-0,0378	-0,0478	0,0199	0,0714	-0,2669
R	N64 (a65)	-0,0090	0,0161	-0,0001	-0,0223	-0,0216	0,0262	-0,0267	-0,0719	0,2622	0,0106	0,0682
R	N65 (a66)	-0,0267	0,0603	0,0086	-0,0508	-0,0354	0,0423	-0,0503	-0,0439	-0,0358	0,0406	-0,0558
R	N66 (a67)	-0,0180	0,0341	0,0021	-0,0265	-0,0201	0,0285	-0,0313	-0,0659	0,1350	0,0715	-0,2755
R	N67 (a68)	-0,0161	0,0286	-0,0014	-0,0249	-0,0224	0,0209	-0,0157	-0,0426	0,1842	-0,0130	0,1176
R	N68 (a69)	-0,0212	0,0450	0,0061	-0,0437	-0,0336	0,0399	-0,0471	-0,0531	0,0740	-0,0050	0,1949
R	N69 (a70)	-0,0291	0,0629	0,0085	-0,0517	-0,0363	0,0422	-0,0495	-0,0452	-0,0191	0,0346	-0,0217
R	N70 (a71)	-0,0317	0,0654	0,0084	-0,0502	-0,0346	0,0360	-0,0408	-0,0241	-0,0334	0,0015	0,0737
R	N71 (a72)	-0,0307	0,0612	0,0087	-0,0498	-0,0369	0,0412	-0,0503	-0,0421	0,0170	0,0241	-0,0725
R	N72 (a73)	-0,0317	0,0652	0,0085	-0,0514	-0,0358	0,0401	-0,0468	-0,0411	-0,0111	0,0297	-0,0382
R	N73 (a74)	-0,0331	0,0665	0,0089	-0,0501	-0,0337	0,0357	-0,0409	-0,0306	-0,0260	0,0146	0,0252
R	N74 (a75)	-0,0320	0,0661	0,0085	-0,0512	-0,0353	0,0394	-0,0456	-0,0385	-0,0199	0,0279	-0,0211
R	N75 (a76)	-0,0319	0,0658	0,0087	-0,0512	-0,0353	0,0394	-0,0462	-0,0365	-0,0280	0,0263	-0,0186
R	N76 (a77)	-0,0337	0,0683	0,0088	-0,0505	-0,0342	0,0356	-0,0405	-0,0277	-0,0241	0,0160	0,0023
R	N77 (a78)	-0,0340	0,0684	0,0087	-0,0497	-0,0337	0,0354	-0,0402	-0,0282	-0,0267	0,0187	-0,0071
R	N78 (a79)	-0,0344	0,0685	0,0088	-0,0496	-0,0333	0,0339	-0,0382	-0,0254	-0,0246	0,0148	0,0003
R	N79 (a80)	-0,0345	0,0689	0,0086	-0,0496	-0,0330	0,0340	-0,0386	-0,0242	-0,0287	0,0157	-0,0028
R	N80 (a81)	-0,0357	0,0696	0,0086	-0,0483	-0,0320	0,0310	-0,0343	-0,0185	-0,0282	0,0093	0,0006
R	N81 (a82)	-0,0357	0,0697	0,0087	-0,0483	-0,0319	0,0307	-0,0338	-0,0175	-0,0294	0,0063	0,0196
R	N82 (a83)	-0,0368	0,0703	0,0086	-0,0471	-0,0308	0,0281	-0,0306	-0,0125	-0,0275	0,0013	0,0209
R	N83 (a84)	-0,0375	0,0707	0,0085	-0,0463	-0,0301	0,0269	-0,0290	-0,0116	-0,0222	0,0036	-0,0011
R	N84 (a85)	-0,0384	0,0709	0,0082	-0,0448	-0,0289	0,0246	-0,0260	-0,0077	-0,0229	-0,0009	0,0074
R	N85 (a86)	-0,0392	0,0711	0,0081	-0,0432	-0,0274	0,0218	-0,0221	-0,0022	-0,0226	-0,0067	0,0212
R	N86 (a87)	-0,0400	0,0713	0,0079	-0,0419	-0,0264	0,0199	-0,0198	0,0002	-0,0207	-0,0082	0,0167
R	N87 (a88)	-0,0408	0,0714	0,0077	-0,0405	-0,0251	0,0181	-0,0175	0,0022	-0,0191	-0,0090	0,0120
R	N88 (a89)	-0,0416	0,0714	0,0075	-0,0389	-0,0237	0,0158	-0,0145	0,0051	-0,0163	-0,0104	0,0085
R	N89 (a90)	-0,0430	0,0711	0,0069	-0,0353	-0,0207	0,0111	-0,0085	0,0119	-0,0146	-0,0165	0,0162

Sistema	Nível de Cinza	Componente Principal										
		V1	V2	V3	V4	V5	V6	V7	V8	V9	V10	V11
R	N91 (a92)	-0,0452	0,0705	0,0060	-0,0301	-0,0166	0,0053	-0,0012	0,0178	-0,0092	-0,0198	0,0145
R	N92 (a93)	-0,0465	0,0697	0,0053	-0,0261	-0,0134	0,0012	0,0040	0,0220	-0,0082	-0,0232	0,0217
R	N93 (a94)	-0,0479	0,0690	0,0045	-0,0224	-0,0104	-0,0023	0,0082	0,0241	-0,0040	-0,0230	0,0159
R	N94 (a95)	-0,0489	0,0679	0,0038	-0,0186	-0,0075	-0,0059	0,0128	0,0276	-0,0021	-0,0255	0,0202
R	N95 (a96)	-0,0499	0,0668	0,0030	-0,0149	-0,0045	-0,0093	0,0169	0,0300	0,0010	-0,0255	0,0158
R	N96 (a97)	-0,0508	0,0656	0,0022	-0,0109	-0,0014	-0,0129	0,0215	0,0325	0,0034	-0,0263	0,0172
R	N97 (a98)	-0,0516	0,0641	0,0013	-0,0071	0,0017	-0,0164	0,0256	0,0345	0,0056	-0,0266	0,0182
R	N98 (a99)	-0,0525	0,0627	0,0004	-0,0032	0,0047	-0,0190	0,0286	0,0348	0,0067	-0,0250	0,0162
R	N99 (a100)	-0,0532	0,0608	-0,0006	0,0010	0,0078	-0,0221	0,0322	0,0362	0,0083	-0,0248	0,0148
R	N100(a101)	-0,0538	0,0583	-0,0019	0,0062	0,0118	-0,0256	0,0362	0,0366	0,0107	-0,0220	0,0107
R	N101(a102)	-0,0545	0,0559	-0,0032	0,0110	0,0154	-0,0279	0,0387	0,0352	0,0115	-0,0193	0,0107
R	N102(a103)	-0,0551	0,0525	-0,0049	0,0170	0,0196	-0,0305	0,0415	0,0331	0,0131	-0,0156	0,0074
R	N103(a104)	-0,0555	0,0491	-0,0066	0,0227	0,0239	-0,0322	0,0431	0,0300	0,0138	-0,0106	0,0040
R	N104(a105)	-0,0558	0,0448	-0,0088	0,0292	0,0285	-0,0339	0,0447	0,0261	0,0157	-0,0056	-0,0002
R	N105(a106)	-0,0560	0,0407	-0,0108	0,0349	0,0324	-0,0341	0,0446	0,0206	0,0154	-0,0005	-0,0015
R	N106(a107)	-0,0559	0,0366	-0,0132	0,0401	0,0359	-0,0336	0,0435	0,0147	0,0153	0,0054	-0,0046
R	N107(a108)	-0,0558	0,0325	-0,0155	0,0447	0,0388	-0,0322	0,0416	0,0078	0,0137	0,0103	-0,0057
R	N108(a109)	-0,0557	0,0288	-0,0181	0,0487	0,0411	-0,0297	0,0384	0,0002	0,0121	0,0158	-0,0079
R	N109(a110)	-0,0554	0,0247	-0,0209	0,0524	0,0430	-0,0270	0,0351	-0,0070	0,0090	0,0202	-0,0057
R	N110(a111)	-0,0546	0,0202	-0,0242	0,0562	0,0448	-0,0234	0,0308	-0,0150	0,0062	0,0248	-0,0079
R	N111(a112)	-0,0535	0,0150	-0,0279	0,0597	0,0465	-0,0176	0,0245	-0,0243	0,0019	0,0308	-0,0076
R	N112(a113)	-0,0520	0,0092	-0,0322	0,0626	0,0476	-0,0115	0,0168	-0,0343	-0,0018	0,0351	-0,0063
R	N113(a114)	-0,0496	0,0022	-0,0366	0,0656	0,0480	-0,0034	0,0086	-0,0449	-0,0066	0,0394	-0,0055
R	N114(a115)	-0,0465	-0,0051	-0,0410	0,0672	0,0478	0,0062	-0,0018	-0,0551	-0,0112	0,0431	-0,0055
R	N115(a116)	-0,0422	-0,0134	-0,0459	0,0673	0,0469	0,0169	-0,0144	-0,0652	-0,0155	0,0458	-0,0034
R	N116(a117)	-0,0361	-0,0225	-0,0500	0,0660	0,0451	0,0291	-0,0288	-0,0736	-0,0188	0,0477	-0,0004
R	N117(a118)	-0,0282	-0,0322	-0,0536	0,0612	0,0404	0,0423	-0,0451	-0,0825	-0,0245	0,0473	0,0064
R	N118(a119)	-0,0187	-0,0415	-0,0551	0,0543	0,0339	0,0554	-0,0600	-0,0843	-0,0270	0,0435	0,0115
R	N119(a120)	-0,0087	-0,0494	-0,0530	0,0458	0,0267	0,0660	-0,0722	-0,0840	-0,0266	0,0386	0,0118
R	N120(a121)	0,0016	-0,0551	-0,0503	0,0350	0,0168	0,0729	-0,0809	-0,0794	-0,0263	0,0267	0,0155
R	N121(a122)	0,0115	-0,0588	-0,0450	0,0222	0,0063	0,0775	-0,0872	-0,0683	-0,0271	0,0160	0,0191
R	N122(a123)	0,0208	-0,0610	-0,0377	0,0092	-0,0035	0,0784	-0,0887	-0,0559	-0,0231	0,0017	0,0199
R	N123(a124)	0,0287	-0,0606	-0,0302	-0,0023	-0,0135	0,0752	-0,0871	-0,0419	-0,0201	-0,0092	0,0179
R	N124(a125)	0,0353	-0,0592	-0,0213	-0,0127	-0,0214	0,0701	-0,0824	-0,0281	-0,0167	-0,0209	0,0158
R	N125(a126)	0,0411	-0,0561	-0,0132	-0,0222	-0,0284	0,0632	-0,0744	-0,0134	-0,0128	-0,0288	0,0134
R	N126(a127)	0,0449	-0,0525	-0,0056	-0,0307	-0,0346	0,0528	-0,0672	-0,0005	-0,0086	-0,0385	0,0097
R	N127(a128)	0,0479	-0,0482	0,0024	-0,0365	-0,0401	0,0446	-0,0566	0,0117	-0,0051	-0,0442	0,0060
R	N128(a129)	0,0500	-0,0443	0,0093	-0,0413	-0,0431	0,0357	-0,0471	0,0200	0,0002	-0,0444	0,0030
R	N129(a130)	0,0516	-0,0400	0,0151	-0,0444	-0,0458	0,0274	-0,0370	0,0294	0,0015	-0,0432	-0,0012
R	N130(a131)	0,0524	-0,0363	0,0211	-0,0467	-0,0473	0,0180	-0,0284	0,0354	0,0042	-0,0419	-0,0051
R	N131(a132)	0,0529	-0,0325	0,0258	-0,0479	-0,0485	0,0096	-0,0196	0,0394	0,0065	-0,0381	-0,0081
R	N132(a133)	0,0531	-0,0290	0,0299	-0,0489	-0,0484	0,0018	-0,0116	0,0421	0,0070	-0,0340	-0,0115
R	N133(a134)	0,0533	-0,0255	0,0337	-0,0487	-0,0484	-0,0057	-0,0049	0,0434	0,0079	-0,0276	-0,0135
R	N134(a135)	0,0533	-0,0224	0,0366	-0,0484	-0,0480	-0,0127	0,0015	0,0425	0,0084	-0,0219	-0,0157
R	N135(a136)	0,0533	-0,0193	0,0391	-0,0480	-0,0466	-0,0195	0,0076	0,0398	0,0086	-0,0140	-0,0171

Sistema	Nível de Cinza	Componente Principal										
		V1	V2	V3	V4	V5	V6	V7	V8	V9	V10	V11
R	N137(a138)	0,0541	-0,0123	0,0430	-0,0451	-0,0424	-0,0286	0,0186	0,0306	0,0075	0,0029	-0,0169
R	N138(a139)	0,0543	-0,0091	0,0443	-0,0438	-0,0397	-0,0327	0,0232	0,0250	0,0070	0,0092	-0,0163
R	N139(a140)	0,0547	-0,0059	0,0453	-0,0414	-0,0376	-0,0359	0,0262	0,0190	0,0063	0,0176	-0,0150
R	N140(a141)	0,0548	-0,0033	0,0459	-0,0408	-0,0341	-0,0384	0,0306	0,0119	0,0059	0,0265	-0,0122
R	N141(a142)	0,0553	0,0002	0,0459	-0,0386	-0,0307	-0,0405	0,0339	0,0032	0,0040	0,0336	-0,0097
R	N142(a143)	0,0560	0,0039	0,0459	-0,0361	-0,0268	-0,0414	0,0363	-0,0041	0,0020	0,0390	-0,0075
R	N143(a144)	0,0565	0,0074	0,0452	-0,0344	-0,0219	-0,0417	0,0401	-0,0142	0,0001	0,0462	-0,0042
R	N144(a145)	0,0567	0,0104	0,0446	-0,0321	-0,0177	-0,0418	0,0423	-0,0238	-0,0016	0,0566	0,0018
R	N145(a146)	0,0573	0,0142	0,0432	-0,0297	-0,0120	-0,0406	0,0437	-0,0321	-0,0014	0,0591	0,0054
R	N146(a147)	0,0572	0,0169	0,0419	-0,0278	-0,0076	-0,0388	0,0467	-0,0421	-0,0052	0,0649	0,0096
R	N147(a148)	0,0577	0,0202	0,0401	-0,0252	-0,0026	-0,0367	0,0461	-0,0477	-0,0046	0,0657	0,0129
R	N148(a149)	0,0578	0,0230	0,0381	-0,0232	0,0024	-0,0337	0,0469	-0,0548	-0,0051	0,0634	0,0150
R	N149(a150)	0,0580	0,0259	0,0362	-0,0204	0,0073	-0,0315	0,0451	-0,0596	-0,0072	0,0651	0,0181
R	N150(a151)	0,0578	0,0281	0,0339	-0,0196	0,0133	-0,0286	0,0454	-0,0649	-0,0099	0,0605	0,0180
R	N151(a152)	0,0579	0,0310	0,0316	-0,0168	0,0184	-0,0248	0,0437	-0,0685	-0,0122	0,0508	0,0171
R	N152(a153)	0,0576	0,0325	0,0284	-0,0170	0,0250	-0,0205	0,0421	-0,0726	-0,0129	0,0463	0,0190
R	N153(a154)	0,0573	0,0340	0,0255	-0,0157	0,0294	-0,0158	0,0407	-0,0762	-0,0125	0,0427	0,0212
R	N154(a155)	0,0571	0,0352	0,0242	-0,0147	0,0329	-0,0126	0,0393	-0,0773	-0,0133	0,0334	0,0195
R	N155(a156)	0,0570	0,0351	0,0213	-0,0162	0,0379	-0,0078	0,0362	-0,0757	-0,0158	0,0322	0,0206
R	N156(a157)	0,0569	0,0361	0,0202	-0,0161	0,0400	-0,0058	0,0372	-0,0741	-0,0147	0,0243	0,0171
R	N157(a158)	0,0568	0,0366	0,0193	-0,0144	0,0412	-0,0043	0,0329	-0,0739	-0,0157	0,0252	0,0198
R	N158(a159)	0,0564	0,0370	0,0168	-0,0150	0,0456	-0,0007	0,0312	-0,0747	-0,0160	0,0112	0,0167
R	N159(a160)	0,0564	0,0386	0,0159	-0,0125	0,0470	0,0009	0,0282	-0,0710	-0,0168	-0,0063	0,0103
R	N160(a161)	0,0560	0,0391	0,0131	-0,0134	0,0513	0,0038	0,0253	-0,0677	-0,0152	-0,0137	0,0093
R	N161(a162)	0,0548	0,0386	0,0105	-0,0139	0,0559	0,0093	0,0231	-0,0698	-0,0152	-0,0191	0,0112
R	N162(a163)	0,0547	0,0411	0,0076	-0,0131	0,0597	0,0089	0,0200	-0,0574	-0,0110	-0,0205	0,0056
R	N163(a164)	0,0539	0,0417	0,0039	-0,0125	0,0634	0,0139	0,0158	-0,0513	-0,0083	-0,0306	0,0035
R	N164(a165)	0,0538	0,0407	0,0035	-0,0142	0,0644	0,0131	0,0150	-0,0521	-0,0113	-0,0195	0,0065
R	N165(a166)	0,0539	0,0417	0,0001	-0,0131	0,0650	0,0150	0,0118	-0,0434	-0,0103	-0,0166	0,0062
R	N166(a167)	0,0536	0,0424	-0,0021	-0,0116	0,0672	0,0175	0,0069	-0,0331	-0,0103	-0,0227	0,0010
R	N167(a168)	0,0528	0,0424	-0,0042	-0,0120	0,0697	0,0176	0,0025	-0,0302	-0,0076	-0,0205	0,0023
R	N168(a168)	0,0526	0,0430	-0,0067	-0,0100	0,0692	0,0214	-0,0022	-0,0167	-0,0041	-0,0271	-0,0007
R	N169(a170)	0,0519	0,0430	-0,0087	-0,0100	0,0714	0,0213	-0,0098	-0,0050	0,0015	-0,0153	0,0026
R	N170(a171)	0,0511	0,0438	-0,0109	-0,0096	0,0717	0,0224	-0,0063	-0,0080	-0,0035	-0,0350	-0,0055
R	N171(a172)	0,0501	0,0417	-0,0145	-0,0124	0,0737	0,0229	-0,0152	0,0109	0,0043	-0,0022	0,0038
R	N172(a173)	0,0506	0,0409	-0,0132	-0,0128	0,0726	0,0234	-0,0191	0,0219	0,0059	0,0011	0,0023
R	N173(a174)	0,0487	0,0409	-0,0173	-0,0099	0,0727	0,0267	-0,0262	0,0340	0,0047	-0,0010	-0,0012
R	N174(a175)	0,0487	0,0392	-0,0171	-0,0135	0,0731	0,0265	-0,0290	0,0417	0,0094	-0,0026	-0,0022
R	N175(a176)	0,0470	0,0389	-0,0248	-0,0126	0,0703	0,0252	-0,0360	0,0643	0,0158	0,0226	0,0030
R	N176(a177)	0,0488	0,0395	-0,0240	-0,0135	0,0698	0,0251	-0,0301	0,0483	0,0127	0,0189	0,0044
R	N177(a178)	0,0473	0,0370	-0,0299	-0,0155	0,0672	0,0246	-0,0367	0,0647	0,0131	0,0198	0,0014
R	N178(a179)	0,0449	0,0364	-0,0330	-0,0169	0,0671	0,0201	-0,0393	0,0757	0,0203	0,0277	0,0005
R	N179(a180)	0,0457	0,0380	-0,0374	-0,0118	0,0618	0,0213	-0,0419	0,0764	0,0149	0,0166	-0,0034
R	N180(a181)	0,0460	0,0389	-0,0314	-0,0143	0,0671	0,0190	-0,0377	0,0720	0,0244	0,0230	-0,0001
R	N181(a182)	0,0418	0,0349	-0,0404	-0,0170	0,0654	0,0153	-0,0480	0,0894	0,0229	0,0391	-0,0005

Sistema	Nível de Cinza	Componente Principal										
		V1	V2	V3	V4	V5	V6	V7	V8	V9	V10	V11
R	N183(a184)	0,0416	0,0345	-0,0460	-0,0183	0,0601	0,0213	-0,0365	0,0910	0,0221	0,0431	-0,0011
R	N184(a185)	0,0440	0,0367	-0,0571	-0,0156	0,0465	0,0014	-0,0341	0,0577	0,0148	0,0168	-0,0046
R	N185(a186)	0,0446	0,0359	-0,0571	-0,0153	0,0441	0,0034	-0,0359	0,0635	0,0126	0,0153	-0,0053
R	N186(a187)	0,0446	0,0374	-0,0588	-0,0119	0,0418	0,0030	-0,0327	0,0541	0,0008	0,0021	-0,0106
R	N187(a188)	0,0428	0,0341	-0,0648	-0,0183	0,0378	-0,0031	-0,0269	0,0522	0,0100	0,0195	-0,0037
R	N188(a189)	0,0402	0,0326	-0,0747	-0,0140	0,0220	-0,0114	-0,0277	0,0426	0,0237	0,0076	-0,0010
R	N189(a190)	0,0392	0,0288	-0,0789	-0,0193	0,0110	-0,0280	-0,0230	0,0304	0,0030	-0,0058	-0,0093
R	N190(a191)	0,0364	0,0273	-0,0775	-0,0131	0,0113	-0,0102	-0,0277	0,0707	0,0067	0,0678	0,0049
R	N191(a192)	0,0339	0,0266	-0,0822	-0,0113	0,0022	-0,0230	-0,0319	0,0617	0,0093	0,0429	-0,0016
R	N192(a193)	0,0340	0,0250	-0,0861	-0,0177	-0,0048	-0,0367	-0,0162	0,0214	0,0083	0,0083	-0,0034
R	N193(a194)	0,0281	0,0184	-0,0905	-0,0157	-0,0235	-0,0396	-0,0102	0,0235	-0,0094	0,0262	-0,0035
R	N194(a195)	0,0301	0,0194	-0,0898	-0,0194	-0,0111	-0,0272	-0,0137	0,0334	0,0149	0,0407	0,0067
R	N195(a196)	0,0280	0,0181	-0,0927	-0,0192	-0,0175	-0,0283	-0,0010	0,0207	0,0035	0,0298	0,0011
R	N196(a197)	0,0223	0,0131	-0,0931	-0,0185	-0,0314	-0,0510	-0,0040	0,0007	-0,0022	0,0327	0,0065
R	N197(a198)	0,0224	0,0133	-0,0931	-0,0174	-0,0361	-0,0490	0,0022	-0,0135	-0,0007	0,0092	0,0044
R	N198(a199)	0,0239	0,0143	-0,0929	-0,0143	-0,0380	-0,0362	0,0143	-0,0126	-0,0079	0,0081	0,0006
R	N199(a200)	0,0208	0,0130	-0,0925	-0,0110	-0,0434	-0,0489	0,0060	-0,0217	-0,0153	-0,0123	-0,0059
R	N200(a201)	0,0223	0,0136	-0,0921	-0,0133	-0,0405	-0,0475	0,0080	-0,0267	-0,0042	-0,0070	0,0014
R	N201(a202)	0,0204	0,0132	-0,0919	-0,0103	-0,0450	-0,0486	0,0098	-0,0260	-0,0235	-0,0146	-0,0069
R	N202(a203)	0,0188	0,0100	-0,0922	-0,0091	-0,0520	-0,0345	0,0227	-0,0238	-0,0170	-0,0110	-0,0053
R	N203(a204)	0,0187	0,0110	-0,0935	-0,0098	-0,0496	-0,0374	0,0166	-0,0225	-0,0054	-0,0099	-0,0007
R	N204(a205)	0,0167	0,0110	-0,0906	-0,0085	-0,0504	-0,0475	0,0175	-0,0452	-0,0093	-0,0456	-0,0071
R	N205(a206)	0,0183	0,0104	-0,0900	-0,0094	-0,0528	-0,0539	0,0115	-0,0283	-0,0199	-0,0128	-0,0057
R	N206(a207)	0,0181	0,0097	-0,0907	-0,0086	-0,0561	-0,0278	0,0326	-0,0364	-0,0027	-0,0251	0,0005
R	N207(a208)	0,0182	0,0095	-0,0923	-0,0081	-0,0562	-0,0252	0,0310	-0,0265	-0,0023	-0,0120	0,0004
R	N208(a209)	0,0196	0,0121	-0,0898	-0,0063	-0,0546	-0,0324	0,0293	-0,0428	-0,0030	-0,0268	0,0015
R	N209(a210)	0,0167	0,0095	-0,0901	-0,0069	-0,0567	-0,0440	0,0185	-0,0426	-0,0036	-0,0274	0,0009
R	N210(a211)	0,0187	0,0117	-0,0893	-0,0037	-0,0562	-0,0433	0,0151	-0,0421	0,0001	-0,0196	0,0043
R	N211(a212)	0,0165	0,0094	-0,0909	-0,0080	-0,0561	-0,0304	0,0319	-0,0380	-0,0094	-0,0414	-0,0076
R	N212(a213)	0,0185	0,0110	-0,0876	-0,0002	-0,0614	-0,0252	0,0316	-0,0441	-0,0129	-0,0208	0,0018
R	N213(a214)	0,0163	0,0083	-0,0890	-0,0039	-0,0622	-0,0249	0,0357	-0,0298	-0,0259	-0,0289	-0,0113
R	N214(a215)	0,0211	0,0124	-0,0867	0,0034	-0,0636	-0,0007	0,0455	-0,0306	0,0011	-0,0182	0,0032
R	N215(a216)	0,0233	0,0134	-0,0536	0,0194	-0,0578	0,0915	0,0865	0,0187	0,0464	0,0074	0,0129
R	N216(a217)	0,0225	0,0137	-0,0699	0,0200	-0,0713	0,0487	0,0685	-0,0001	0,0165	0,0051	0,0082
R	N217(a218)	0,0216	0,0148	-0,0262	0,0307	-0,0443	0,1246	0,0942	0,0261	0,0342	-0,0222	-0,0002
R	N218(a219)	0,0196	0,0126	-0,0255	0,0287	-0,0459	0,1249	0,1004	0,0174	0,0518	0,0133	0,0175
R	N219(a220)	0,0343	0,0323	-0,0025	0,0509	-0,0279	0,1088	0,0741	0,0221	-0,0086	-0,0022	-0,0085
R	N220(a221)	0,0169	0,0102	-0,0136	0,0347	-0,0378	0,1348	0,0933	0,0438	-0,0113	0,0359	-0,0007
R	N221(a222)	0,0206	0,0117	-0,0178	0,0299	-0,0392	0,1338	0,1020	0,0359	-0,0135	0,0301	-0,0029
R	N222(a223)	0,0247	0,0170	-0,0074	0,0393	-0,0402	0,1275	0,0935	0,0347	-0,0125	0,0355	-0,0017
R	N223(a224)	0,0345	0,0308	-0,0023	0,0351	-0,0139	0,1066	0,0905	0,0019	-0,0130	-0,0301	-0,0182
R	N224(a225)	0,0197	0,0124	-0,0097	0,0364	-0,0445	0,1271	0,0947	0,0530	-0,0080	0,0591	0,0001
R	N225(a226)	0,0264	0,0214	-0,0044	0,0488	-0,0384	0,1160	0,0727	0,0240	-0,0165	0,0297	0,0025
R	N226(a227)	0,0312	0,0299	-0,0039	0,0314	-0,0072	0,1028	0,0816	0,0030	-0,0035	-0,1218	-0,0452
R	N227(a228)	0,0312	0,0281	0,0092	0,0657	-0,0537	0,0647	0,0337	0,0422	-0,0096	0,1011	0,0203

Sistema	Nível de Cinza	Componente Principal										
		V1	V2	V3	V4	V5	V6	V7	V8	V9	V10	V11
R	N229(a230)	0,0350	0,0400	0,0177	0,0754	-0,0351	0,0121	-0,0270	0,0091	-0,0076	-0,0016	-0,0021
R	N230(a231)	0,0310	0,0367	0,0241	0,0801	-0,0476	-0,0144	-0,0415	0,0058	-0,0069	0,0712	0,0250
R	N231(a232)	0,0377	0,0450	0,0239	0,0748	-0,0278	-0,0066	-0,0266	-0,0217	-0,0086	0,0009	0,0090
R	N232(a233)	0,0338	0,0415	0,0238	0,0807	-0,0372	-0,0112	-0,0355	-0,0090	-0,0080	0,0286	0,0153
R	N233(a234)	0,0346	0,0415	0,0270	0,0736	-0,0385	-0,0260	-0,0365	-0,0064	0,0011	0,0098	0,0091
R	N234(a235)	0,0303	0,0359	0,0270	0,0782	-0,0524	-0,0283	-0,0407	0,0078	-0,0026	0,0874	0,0277
R	N235(a236)	0,0239	0,0282	0,0243	0,0808	-0,0607	-0,0197	-0,0498	0,0213	-0,0060	0,1043	0,0326
R	N236(a237)	0,0324	0,0388	0,0198	0,0751	-0,0330	-0,0067	-0,0456	0,0054	-0,0068	0,0038	0,0027
R	N237(a238)	0,0324	0,0381	0,0283	0,0746	-0,0445	-0,0317	-0,0430	0,0122	0,0029	0,0189	0,0058
R	N238(a239)	0,0235	0,0302	0,0265	0,0819	-0,0619	-0,0347	-0,0533	0,0265	0,0030	0,0835	0,0228
R	N239(a240)	0,0332	0,0405	0,0232	0,0747	-0,0385	-0,0250	-0,0462	0,0166	0,0047	0,0230	0,0042
R	N240(a241)	0,0296	0,0390	0,0268	0,0791	-0,0477	-0,0328	-0,0482	0,0194	0,0117	0,0029	-0,0001
R	N241(a242)	0,0320	0,0415	0,0263	0,0818	-0,0426	-0,0284	-0,0451	0,0024	0,0024	0,0072	0,0042
R	N242(a243)	0,0223	0,0293	0,0265	0,0814	-0,0630	-0,0368	-0,0570	0,0389	0,0087	0,0669	0,0154
R	N243(a244)	0,0370	0,0483	0,0235	0,0767	-0,0241	-0,0160	-0,0380	-0,0113	0,0041	-0,0696	-0,0162
R	N244(a245)	0,0326	0,0434	0,0234	0,0825	-0,0349	-0,0226	-0,0455	0,0078	0,0043	-0,0173	-0,0045
R	N245(a246)	0,0339	0,0449	0,0252	0,0779	-0,0348	-0,0265	-0,0420	0,0043	0,0102	-0,0324	-0,0085
R	N246(a247)	0,0285	0,0380	0,0268	0,0826	-0,0518	-0,0324	-0,0512	0,0201	0,0088	0,0216	0,0049
R	N247(a248)	0,0263	0,0353	0,0265	0,0798	-0,0544	-0,0364	-0,0510	0,0275	0,0120	0,0384	0,0081
R	N248(a249)	0,0372	0,0468	0,0218	0,0766	-0,0252	-0,0121	-0,0422	-0,0024	0,0009	-0,0476	-0,0121
R	N249(a250)	0,0394	0,0516	0,0186	0,0617	0,0018	-0,0045	-0,0207	-0,0354	0,0036	-0,1398	-0,0329
R	N250(a251)	0,0365	0,0482	0,0234	0,0779	-0,0252	-0,0197	-0,0389	-0,0047	0,0067	-0,0579	-0,0144
R	N251(a252)	0,0380	0,0471	0,0197	0,0724	-0,0181	-0,0065	-0,0391	-0,0064	-0,0013	-0,0597	-0,0153
R	N252(a253)	0,0389	0,0513	0,0185	0,0597	0,0028	-0,0060	-0,0188	-0,0355	0,0055	-0,1419	-0,0336
R	N253(a254)	0,0405	0,0507	0,0111	0,0454	0,0242	0,0120	-0,0099	-0,0443	-0,0018	-0,1695	-0,0415
R	N254(a255)	0,0395	0,0517	0,0181	0,0606	0,0036	-0,0031	-0,0197	-0,0370	0,0030	-0,1437	-0,0338
R	N255(a256)	0,0395	0,0496	0,0117	0,0479	0,0184	0,0054	-0,0139	-0,0302	0,0022	-0,1402	-0,0361
G	N55 (a312)	-0,0069	0,0035	-0,0014	0,0063	0,0052	-0,0059	0,0081	-0,0083	0,1251	0,0108	-0,2209
G	N59 (a316)	-0,0047	0,0014	-0,0054	0,0015	-0,0025	0,0066	0,0002	-0,0569	0,2803	0,0169	-0,0702
G	N62 (a319)	0,0019	-0,0064	-0,0007	-0,0109	-0,0150	0,0169	-0,0196	-0,0540	0,2668	-0,0258	0,1681
G	N63 (a320)	-0,0163	0,0380	0,0056	-0,0337	-0,0239	0,0310	-0,0378	-0,0478	0,0199	0,0714	-0,2669
G	N64 (a321)	-0,0090	0,0161	-0,0001	-0,0223	-0,0216	0,0262	-0,0267	-0,0719	0,2622	0,0106	0,0682
G	N65 (a322)	-0,0267	0,0603	0,0086	-0,0508	-0,0354	0,0423	-0,0503	-0,0439	-0,0358	0,0406	-0,0558
G	N66 (a323)	-0,0180	0,0341	0,0021	-0,0265	-0,0201	0,0285	-0,0313	-0,0659	0,1350	0,0715	-0,2755
G	N67 (a324)	-0,0161	0,0286	-0,0014	-0,0249	-0,0224	0,0209	-0,0157	-0,0426	0,1842	-0,0130	0,1176
G	N68 (a325)	-0,0212	0,0450	0,0061	-0,0437	-0,0336	0,0399	-0,0471	-0,0531	0,0740	-0,0050	0,1949
G	N69 (a326)	-0,0291	0,0625	0,0085	-0,0517	-0,0364	0,0424	-0,0501	-0,0451	-0,0196	0,0336	-0,0225
G	N70 (a327)	-0,0317	0,0654	0,0084	-0,0502	-0,0346	0,0360	-0,0408	-0,0241	-0,0334	0,0015	0,0737
G	N71 (a328)	-0,0307	0,0601	0,0088	-0,0495	-0,0371	0,0413	-0,0512	-0,0418	0,0160	0,0221	-0,0736
G	N72 (a329)	-0,0318	0,0644	0,0086	-0,0512	-0,0360	0,0403	-0,0476	-0,0408	-0,0119	0,0281	-0,0393
G	N73 (a330)	-0,0331	0,0661	0,0089	-0,0501	-0,0339	0,0359	-0,0414	-0,0306	-0,0264	0,0138	0,0246
G	N74 (a331)	-0,0321	0,0659	0,0086	-0,0512	-0,0354	0,0395	-0,0460	-0,0385	-0,0201	0,0274	-0,0215
G	N75 (a332)	-0,0320	0,0656	0,0088	-0,0512	-0,0354	0,0395	-0,0466	-0,0365	-0,0283	0,0257	-0,0191
G	N76 (a333)	-0,0337	0,0680	0,0088	-0,0505	-0,0343	0,0358	-0,0409	-0,0277	-0,0245	0,0153	0,0017
G	N77 (a334)	-0,0340	0,0683	0,0087	-0,0498	-0,0338	0,0354	-0,0404	-0,0282	-0,0268	0,0185	-0,0073

Sistema	Nível de Cinza	Componente Principal										
		V1	V2	V3	V4	V5	V6	V7	V8	V9	V10	V11
G	N79 (a336)	-0,0345	0,0688	0,0087	-0,0496	-0,0331	0,0341	-0,0387	-0,0242	-0,0288	0,0154	-0,0030
G	N80 (a337)	-0,0357	0,0696	0,0086	-0,0483	-0,0321	0,0310	-0,0344	-0,0185	-0,0283	0,0092	0,0005
G	N81 (a338)	-0,0357	0,0697	0,0087	-0,0483	-0,0320	0,0307	-0,0339	-0,0175	-0,0295	0,0061	0,0195
G	N82 (a339)	-0,0368	0,0702	0,0086	-0,0471	-0,0308	0,0282	-0,0306	-0,0125	-0,0276	0,0012	0,0208
G	N83 (a340)	-0,0375	0,0707	0,0085	-0,0463	-0,0301	0,0270	-0,0291	-0,0116	-0,0222	0,0035	-0,0012
G	N84 (a341)	-0,0384	0,0709	0,0082	-0,0448	-0,0289	0,0246	-0,0260	-0,0077	-0,0230	-0,0009	0,0073
G	N85 (a342)	-0,0392	0,0711	0,0081	-0,0432	-0,0275	0,0218	-0,0222	-0,0022	-0,0227	-0,0068	0,0212
G	N86 (a343)	-0,0400	0,0712	0,0080	-0,0419	-0,0264	0,0199	-0,0199	0,0002	-0,0207	-0,0083	0,0167
G	N87 (a344)	-0,0408	0,0714	0,0077	-0,0405	-0,0251	0,0181	-0,0176	0,0022	-0,0191	-0,0090	0,0120
G	N88 (a345)	-0,0416	0,0714	0,0075	-0,0389	-0,0237	0,0158	-0,0145	0,0051	-0,0163	-0,0104	0,0085
G	N89 (a346)	-0,0430	0,0711	0,0069	-0,0352	-0,0207	0,0111	-0,0084	0,0119	-0,0145	-0,0165	0,0163
G	N90 (a347)	-0,0439	0,0708	0,0066	-0,0332	-0,0191	0,0086	-0,0052	0,0147	-0,0131	-0,0192	0,0213
G	N91 (a348)	-0,0451	0,0705	0,0060	-0,0301	-0,0166	0,0053	-0,0012	0,0178	-0,0092	-0,0197	0,0145
G	N92 (a349)	-0,0465	0,0698	0,0053	-0,0261	-0,0134	0,0012	0,0041	0,0220	-0,0082	-0,0231	0,0218
G	N93 (a350)	-0,0478	0,0690	0,0045	-0,0224	-0,0104	-0,0023	0,0083	0,0241	-0,0039	-0,0229	0,0159
G	N94 (a351)	-0,0488	0,0679	0,0037	-0,0186	-0,0075	-0,0060	0,0129	0,0276	-0,0020	-0,0253	0,0203
G	N95 (a352)	-0,0498	0,0669	0,0030	-0,0149	-0,0045	-0,0093	0,0170	0,0300	0,0011	-0,0254	0,0159
G	N96 (a353)	-0,0508	0,0656	0,0022	-0,0109	-0,0014	-0,0130	0,0216	0,0325	0,0035	-0,0261	0,0174
G	N97 (a354)	-0,0516	0,0642	0,0013	-0,0071	0,0017	-0,0164	0,0257	0,0345	0,0057	-0,0264	0,0183
G	N98 (a355)	-0,0525	0,0627	0,0004	-0,0032	0,0048	-0,0190	0,0287	0,0348	0,0068	-0,0249	0,0163
G	N99 (a356)	-0,0531	0,0608	-0,0006	0,0010	0,0078	-0,0221	0,0323	0,0362	0,0084	-0,0246	0,0149
G	N100(a357)	-0,0538	0,0584	-0,0019	0,0062	0,0118	-0,0256	0,0363	0,0366	0,0107	-0,0218	0,0108
G	N101(a358)	-0,0545	0,0559	-0,0032	0,0110	0,0154	-0,0279	0,0388	0,0352	0,0116	-0,0191	0,0108
G	N102(a359)	-0,0550	0,0525	-0,0049	0,0170	0,0196	-0,0305	0,0416	0,0331	0,0131	-0,0154	0,0075
G	N103(a360)	-0,0555	0,0491	-0,0067	0,0227	0,0239	-0,0322	0,0431	0,0299	0,0139	-0,0105	0,0041
G	N104(a361)	-0,0557	0,0448	-0,0088	0,0291	0,0285	-0,0339	0,0447	0,0261	0,0157	-0,0054	-0,0001
G	N105(a362)	-0,0560	0,0407	-0,0108	0,0349	0,0324	-0,0341	0,0447	0,0206	0,0154	-0,0003	-0,0013
G	N106(a363)	-0,0558	0,0366	-0,0132	0,0401	0,0359	-0,0336	0,0435	0,0147	0,0153	0,0055	-0,0045
G	N107(a364)	-0,0558	0,0325	-0,0155	0,0447	0,0388	-0,0323	0,0417	0,0078	0,0138	0,0105	-0,0056
G	N108(a365)	-0,0557	0,0288	-0,0181	0,0487	0,0411	-0,0297	0,0384	0,0002	0,0122	0,0159	-0,0078
G	N109(a366)	-0,0553	0,0248	-0,0209	0,0524	0,0430	-0,0270	0,0352	-0,0070	0,0090	0,0203	-0,0056
G	N110(a367)	-0,0546	0,0202	-0,0242	0,0561	0,0448	-0,0234	0,0308	-0,0150	0,0062	0,0249	-0,0079
G	N111(a368)	-0,0535	0,0150	-0,0279	0,0597	0,0465	-0,0176	0,0245	-0,0243	0,0019	0,0309	-0,0075
G	N112(a369)	-0,0520	0,0092	-0,0322	0,0626	0,0476	-0,0115	0,0169	-0,0343	-0,0017	0,0351	-0,0062
G	N113(a370)	-0,0496	0,0022	-0,0366	0,0656	0,0480	-0,0034	0,0087	-0,0449	-0,0065	0,0396	-0,0054
G	N114(a371)	-0,0465	-0,0050	-0,0410	0,0672	0,0478	0,0062	-0,0017	-0,0551	-0,0111	0,0433	-0,0053
G	N115(a372)	-0,0422	-0,0133	-0,0459	0,0673	0,0469	0,0168	-0,0143	-0,0652	-0,0154	0,0459	-0,0033
G	N116(a373)	-0,0361	-0,0224	-0,0500	0,0660	0,0452	0,0291	-0,0287	-0,0736	-0,0187	0,0479	-0,0002
G	N117(a374)	-0,0282	-0,0321	-0,0537	0,0613	0,0404	0,0423	-0,0450	-0,0825	-0,0244	0,0475	0,0066
G	N118(a375)	-0,0186	-0,0414	-0,0551	0,0544	0,0339	0,0554	-0,0599	-0,0844	-0,0268	0,0438	0,0118
G	N119(a376)	-0,0087	-0,0493	-0,0531	0,0458	0,0268	0,0660	-0,0721	-0,0841	-0,0264	0,0388	0,0121
G	N120(a377)	0,0017	-0,0550	-0,0504	0,0350	0,0169	0,0729	-0,0808	-0,0795	-0,0262	0,0269	0,0157
G	N121(a378)	0,0116	-0,0587	-0,0451	0,0222	0,0064	0,0774	-0,0870	-0,0684	-0,0269	0,0164	0,0195
G	N122(a379)	0,0208	-0,0609	-0,0378	0,0092	-0,0034	0,0784	-0,0885	-0,0560	-0,0229	0,0021	0,0202
G	N123(a380)	0,0287	-0,0605	-0,0303	-0,0023	-0,0135	0,0752	-0,0869	-0,0420	-0,0199	-0,0087	0,0183

Sistema	Nível de Cinza	Componente Principal										
		V1	V2	V3	V4	V5	V6	V7	V8	V9	V10	V11
G	N125(a382)	0,0412	-0,0560	-0,0132	-0,0223	-0,0283	0,0632	-0,0742	-0,0135	-0,0126	-0,0284	0,0137
G	N126(a383)	0,0450	-0,0523	-0,0056	-0,0307	-0,0345	0,0527	-0,0670	-0,0005	-0,0084	-0,0381	0,0101
G	N127(a384)	0,0480	-0,0481	0,0024	-0,0365	-0,0401	0,0446	-0,0564	0,0117	-0,0049	-0,0438	0,0064
G	N128(a385)	0,0501	-0,0441	0,0093	-0,0413	-0,0430	0,0357	-0,0468	0,0199	0,0005	-0,0440	0,0033
G	N129(a386)	0,0517	-0,0398	0,0151	-0,0444	-0,0458	0,0273	-0,0367	0,0294	0,0018	-0,0428	-0,0009
G	N130(a387)	0,0525	-0,0361	0,0211	-0,0468	-0,0472	0,0179	-0,0282	0,0354	0,0044	-0,0415	-0,0048
G	N131(a388)	0,0530	-0,0323	0,0258	-0,0479	-0,0485	0,0096	-0,0194	0,0394	0,0067	-0,0378	-0,0078
G	N132(a389)	0,0532	-0,0289	0,0299	-0,0490	-0,0484	0,0018	-0,0114	0,0421	0,0072	-0,0337	-0,0112
G	N133(a390)	0,0533	-0,0254	0,0337	-0,0487	-0,0484	-0,0057	-0,0047	0,0434	0,0080	-0,0274	-0,0134
G	N134(a391)	0,0533	-0,0223	0,0366	-0,0484	-0,0480	-0,0127	0,0016	0,0425	0,0085	-0,0217	-0,0155
G	N135(a392)	0,0533	-0,0193	0,0391	-0,0480	-0,0466	-0,0195	0,0076	0,0398	0,0086	-0,0140	-0,0170
G	N136(a393)	0,0537	-0,0156	0,0414	-0,0463	-0,0450	-0,0246	0,0133	0,0355	0,0089	-0,0050	-0,0164
G	N137(a394)	0,0541	-0,0123	0,0430	-0,0451	-0,0424	-0,0286	0,0185	0,0306	0,0075	0,0029	-0,0169
G	N138(a395)	0,0543	-0,0092	0,0443	-0,0438	-0,0398	-0,0326	0,0231	0,0250	0,0069	0,0090	-0,0164
G	N139(a396)	0,0547	-0,0060	0,0453	-0,0414	-0,0377	-0,0358	0,0261	0,0191	0,0062	0,0174	-0,0152
G	N140(a397)	0,0548	-0,0034	0,0459	-0,0408	-0,0341	-0,0384	0,0304	0,0119	0,0057	0,0262	-0,0124
G	N141(a398)	0,0553	0,0001	0,0460	-0,0387	-0,0307	-0,0404	0,0336	0,0033	0,0038	0,0333	-0,0100
G	N142(a399)	0,0560	0,0037	0,0460	-0,0361	-0,0268	-0,0414	0,0361	-0,0041	0,0019	0,0387	-0,0078
G	N143(a400)	0,0566	0,0072	0,0453	-0,0344	-0,0220	-0,0417	0,0399	-0,0141	-0,0002	0,0458	-0,0045
G	N144(a401)	0,0567	0,0103	0,0446	-0,0321	-0,0178	-0,0418	0,0421	-0,0238	-0,0018	0,0562	0,0015
G	N145(a402)	0,0573	0,0141	0,0433	-0,0298	-0,0121	-0,0406	0,0435	-0,0321	-0,0017	0,0588	0,0051
G	N146(a403)	0,0573	0,0167	0,0420	-0,0279	-0,0077	-0,0388	0,0465	-0,0421	-0,0054	0,0646	0,0093
G	N147(a404)	0,0577	0,0201	0,0402	-0,0252	-0,0027	-0,0367	0,0459	-0,0477	-0,0047	0,0654	0,0127
G	N148(a405)	0,0579	0,0229	0,0382	-0,0232	0,0024	-0,0336	0,0467	-0,0548	-0,0053	0,0631	0,0147
G	N149(a406)	0,0580	0,0258	0,0363	-0,0204	0,0072	-0,0315	0,0449	-0,0596	-0,0074	0,0649	0,0178
G	N150(a407)	0,0578	0,0280	0,0339	-0,0196	0,0132	-0,0285	0,0452	-0,0649	-0,0100	0,0602	0,0178
G	N151(a408)	0,0580	0,0309	0,0317	-0,0168	0,0184	-0,0248	0,0436	-0,0686	-0,0124	0,0506	0,0169
G	N152(a409)	0,0577	0,0325	0,0284	-0,0170	0,0250	-0,0205	0,0420	-0,0726	-0,0131	0,0461	0,0189
G	N153(a410)	0,0573	0,0340	0,0256	-0,0157	0,0293	-0,0158	0,0406	-0,0763	-0,0126	0,0426	0,0211
G	N154(a411)	0,0572	0,0351	0,0242	-0,0147	0,0329	-0,0126	0,0393	-0,0773	-0,0134	0,0332	0,0194
G	N155(a412)	0,0571	0,0351	0,0213	-0,0162	0,0379	-0,0078	0,0362	-0,0757	-0,0159	0,0321	0,0205
G	N156(a413)	0,0569	0,0360	0,0202	-0,0161	0,0400	-0,0058	0,0372	-0,0741	-0,0147	0,0242	0,0170
G	N157(a414)	0,0568	0,0365	0,0193	-0,0144	0,0412	-0,0043	0,0329	-0,0739	-0,0158	0,0252	0,0197
G	N158(a415)	0,0564	0,0370	0,0168	-0,0150	0,0456	-0,0006	0,0312	-0,0747	-0,0161	0,0111	0,0166
G	N159(a416)	0,0564	0,0386	0,0159	-0,0125	0,0470	0,0009	0,0282	-0,0710	-0,0168	-0,0063	0,0103
G	N160(a417)	0,0560	0,0391	0,0131	-0,0134	0,0513	0,0038	0,0253	-0,0677	-0,0152	-0,0137	0,0093
G	N161(a418)	0,0548	0,0386	0,0105	-0,0139	0,0559	0,0093	0,0231	-0,0698	-0,0152	-0,0191	0,0112
G	N162(a419)	0,0547	0,0411	0,0076	-0,0131	0,0597	0,0089	0,0200	-0,0574	-0,0110	-0,0205	0,0056
G	N163(a420)	0,0539	0,0417	0,0039	-0,0125	0,0634	0,0139	0,0158	-0,0513	-0,0083	-0,0306	0,0035
G	N164(a421)	0,0538	0,0407	0,0035	-0,0142	0,0644	0,0131	0,0150	-0,0521	-0,0113	-0,0195	0,0065
G	N165(a422)	0,0539	0,0417	0,0001	-0,0131	0,0650	0,0150	0,0118	-0,0434	-0,0103	-0,0166	0,0062
G	N166(a423)	0,0536	0,0424	-0,0021	-0,0116	0,0672	0,0175	0,0069	-0,0331	-0,0103	-0,0227	0,0010
G	N167(a424)	0,0528	0,0424	-0,0042	-0,0120	0,0697	0,0176	0,0025	-0,0302	-0,0076	-0,0205	0,0023
G	N168(a425)	0,0526	0,0430	-0,0067	-0,0100	0,0692	0,0214	-0,0022	-0,0167	-0,0041	-0,0271	-0,0007
G	N169(a426)	0,0519	0,0430	-0,0087	-0,0100	0,0714	0,0213	-0,0098	-0,0050	0,0015	-0,0153	0,0026



Sistema	Nível de Cinza	Componente Principal										
		V1	V2	V3	V4	V5	V6	V7	V8	V9	V10	V11
G	N171(a428)	0,0501	0,0417	-0,0145	-0,0124	0,0737	0,0229	-0,0152	0,0109	0,0043	-0,0022	0,0038
G	N172(a429)	0,0506	0,0409	-0,0132	-0,0128	0,0726	0,0234	-0,0191	0,0219	0,0059	0,0011	0,0023
G	N173(a430)	0,0487	0,0409	-0,0173	-0,0099	0,0727	0,0267	-0,0262	0,0340	0,0047	-0,0010	-0,0012
G	N174(a431)	0,0487	0,0392	-0,0171	-0,0135	0,0731	0,0265	-0,0290	0,0417	0,0094	-0,0026	-0,0022
G	N175(a432)	0,0470	0,0389	-0,0248	-0,0126	0,0703	0,0252	-0,0360	0,0643	0,0158	0,0226	0,0030
G	N176(a433)	0,0488	0,0395	-0,0240	-0,0135	0,0698	0,0251	-0,0301	0,0483	0,0127	0,0189	0,0044
G	N177(a434)	0,0473	0,0370	-0,0299	-0,0155	0,0672	0,0246	-0,0367	0,0647	0,0131	0,0198	0,0014
G	N178(a435)	0,0449	0,0364	-0,0330	-0,0169	0,0671	0,0201	-0,0393	0,0757	0,0203	0,0277	0,0005
G	N179(a436)	0,0457	0,0380	-0,0374	-0,0118	0,0618	0,0213	-0,0419	0,0764	0,0149	0,0166	-0,0034
G	N180(a437)	0,0460	0,0389	-0,0314	-0,0143	0,0671	0,0190	-0,0377	0,0720	0,0244	0,0230	-0,0001
G	N181(a438)	0,0418	0,0349	-0,0404	-0,0170	0,0654	0,0153	-0,0480	0,0894	0,0229	0,0391	-0,0005
G	N182(a439)	0,0431	0,0365	-0,0413	-0,0142	0,0624	0,0185	-0,0462	0,0823	0,0221	0,0254	-0,0008
G	N183(a440)	0,0416	0,0345	-0,0460	-0,0183	0,0601	0,0213	-0,0365	0,0910	0,0221	0,0431	-0,0011
G	N184(a441)	0,0440	0,0367	-0,0571	-0,0156	0,0465	0,0014	-0,0341	0,0577	0,0148	0,0168	-0,0046
G	N185(a442)	0,0446	0,0359	-0,0571	-0,0153	0,0441	0,0034	-0,0359	0,0635	0,0126	0,0153	-0,0053
G	N186(a443)	0,0446	0,0374	-0,0588	-0,0119	0,0418	0,0030	-0,0327	0,0541	0,0008	0,0021	-0,0106
G	N187(a444)	0,0428	0,0341	-0,0648	-0,0183	0,0378	-0,0031	-0,0269	0,0522	0,0100	0,0195	-0,0037
G	N188(a445)	0,0402	0,0326	-0,0747	-0,0140	0,0220	-0,0114	-0,0277	0,0426	0,0237	0,0076	-0,0010
G	N189(a446)	0,0392	0,0288	-0,0789	-0,0193	0,0110	-0,0280	-0,0230	0,0304	0,0030	-0,0058	-0,0093
G	N190(a447)	0,0364	0,0273	-0,0775	-0,0131	0,0113	-0,0102	-0,0277	0,0707	0,0067	0,0678	0,0049
G	N191(a448)	0,0339	0,0266	-0,0822	-0,0113	0,0022	-0,0230	-0,0319	0,0617	0,0093	0,0429	-0,0016
G	N192(a449)	0,0340	0,0250	-0,0861	-0,0177	-0,0048	-0,0367	-0,0162	0,0214	0,0083	0,0083	-0,0034
G	N193(a450)	0,0281	0,0184	-0,0905	-0,0157	-0,0235	-0,0396	-0,0102	0,0235	-0,0094	0,0262	-0,0035
G	N194(a451)	0,0301	0,0194	-0,0898	-0,0194	-0,0111	-0,0272	-0,0137	0,0334	0,0149	0,0407	0,0067
G	N195(a452)	0,0280	0,0181	-0,0927	-0,0192	-0,0175	-0,0283	-0,0010	0,0207	0,0035	0,0298	0,0011
G	N196(a453)	0,0223	0,0131	-0,0931	-0,0185	-0,0314	-0,0510	-0,0040	0,0007	-0,0022	0,0327	0,0065
G	N197(a454)	0,0224	0,0133	-0,0931	-0,0174	-0,0361	-0,0490	0,0022	-0,0135	-0,0007	0,0092	0,0044
G	N198(a455)	0,0239	0,0143	-0,0929	-0,0143	-0,0380	-0,0362	0,0143	-0,0126	-0,0079	0,0081	0,0006
G	N199(a456)	0,0208	0,0130	-0,0925	-0,0110	-0,0434	-0,0489	0,0060	-0,0217	-0,0153	-0,0123	-0,0059
G	N200(a457)	0,0223	0,0136	-0,0921	-0,0133	-0,0405	-0,0475	0,0080	-0,0267	-0,0042	-0,0070	0,0014
G	N201(a458)	0,0204	0,0132	-0,0919	-0,0103	-0,0450	-0,0486	0,0098	-0,0260	-0,0235	-0,0146	-0,0069
G	N202(a459)	0,0188	0,0100	-0,0922	-0,0091	-0,0520	-0,0345	0,0227	-0,0238	-0,0170	-0,0110	-0,0053
G	N203(a460)	0,0187	0,0110	-0,0935	-0,0098	-0,0496	-0,0374	0,0166	-0,0225	-0,0054	-0,0099	-0,0007
G	N204(a461)	0,0167	0,0110	-0,0906	-0,0085	-0,0504	-0,0475	0,0175	-0,0452	-0,0093	-0,0456	-0,0071
G	N205(a462)	0,0183	0,0104	-0,0900	-0,0094	-0,0528	-0,0539	0,0115	-0,0283	-0,0199	-0,0128	-0,0057
G	N206(a463)	0,0181	0,0097	-0,0907	-0,0086	-0,0561	-0,0278	0,0326	-0,0364	-0,0027	-0,0251	0,0005
G	N207(a464)	0,0182	0,0095	-0,0923	-0,0081	-0,0562	-0,0252	0,0310	-0,0265	-0,0023	-0,0120	0,0004
G	N208(a465)	0,0196	0,0121	-0,0898	-0,0063	-0,0546	-0,0324	0,0293	-0,0428	-0,0030	-0,0268	0,0015
G	N209(a466)	0,0167	0,0095	-0,0901	-0,0069	-0,0567	-0,0440	0,0185	-0,0426	-0,0036	-0,0274	0,0009
G	N210(a467)	0,0187	0,0117	-0,0893	-0,0037	-0,0562	-0,0433	0,0151	-0,0421	0,0001	-0,0196	0,0043
G	N211(a468)	0,0165	0,0094	-0,0909	-0,0080	-0,0561	-0,0304	0,0319	-0,0380	-0,0094	-0,0414	-0,0076
G	N212(a469)	0,0185	0,0110	-0,0876	-0,0002	-0,0614	-0,0252	0,0316	-0,0441	-0,0129	-0,0208	0,0018
G	N213(a470)	0,0163	0,0083	-0,0890	-0,0039	-0,0622	-0,0249	0,0357	-0,0298	-0,0259	-0,0289	-0,0113
G	N214(a471)	0,0211	0,0124	-0,0867	0,0034	-0,0636	-0,0007	0,0455	-0,0306	0,0011	-0,0182	0,0032
G	N215(a472)	0,0233	0,0134	-0,0536	0,0194	-0,0578	0,0915	0,0865	0,0187	0,0464	0,0074	0,0129

Sistema	Nível de Cinza	Componente Principal										
		V1	V2	V3	V4	V5	V6	V7	V8	V9	V10	V11
G	N217(a474)	0,0216	0,0148	-0,0262	0,0307	-0,0443	0,1246	0,0942	0,0261	0,0342	-0,0222	-0,0002
G	N218(a475)	0,0196	0,0126	-0,0255	0,0287	-0,0459	0,1249	0,1004	0,0174	0,0518	0,0133	0,0175
G	N219(a476)	0,0343	0,0323	-0,0025	0,0509	-0,0279	0,1088	0,0741	0,0221	-0,0086	-0,0022	-0,0085
G	N220(a477)	0,0169	0,0102	-0,0136	0,0347	-0,0378	0,1348	0,0933	0,0438	-0,0113	0,0359	-0,0007
G	N221(a478)	0,0206	0,0117	-0,0178	0,0299	-0,0392	0,1338	0,1020	0,0359	-0,0135	0,0301	-0,0029
G	N222(a479)	0,0247	0,0170	-0,0074	0,0393	-0,0402	0,1275	0,0935	0,0347	-0,0125	0,0355	-0,0017
G	N223(a480)	0,0345	0,0308	-0,0023	0,0351	-0,0139	0,1066	0,0905	0,0019	-0,0130	-0,0301	-0,0182
G	N224(a481)	0,0197	0,0124	-0,0097	0,0364	-0,0445	0,1271	0,0947	0,0530	-0,0080	0,0591	0,0001
G	N225(a482)	0,0264	0,0214	-0,0044	0,0488	-0,0384	0,1160	0,0727	0,0240	-0,0165	0,0297	0,0025
G	N226(a483)	0,0312	0,0299	-0,0039	0,0314	-0,0072	0,1028	0,0816	0,0030	-0,0035	-0,1218	-0,0452
G	N227(a484)	0,0312	0,0281	0,0092	0,0657	-0,0537	0,0647	0,0337	0,0422	-0,0096	0,1011	0,0203
G	N228(a485)	0,0396	0,0402	0,0154	0,0709	-0,0423	0,0481	0,0255	0,0090	-0,0110	0,0310	0,0036
G	N229(a486)	0,0350	0,0400	0,0177	0,0754	-0,0351	0,0121	-0,0270	0,0091	-0,0076	-0,0016	-0,0021
G	N230(a487)	0,0310	0,0367	0,0241	0,0801	-0,0476	-0,0144	-0,0415	0,0058	-0,0069	0,0712	0,0250
G	N231(a488)	0,0377	0,0450	0,0239	0,0748	-0,0278	-0,0066	-0,0266	-0,0217	-0,0086	0,0009	0,0090
G	N232(a489)	0,0338	0,0415	0,0238	0,0807	-0,0372	-0,0112	-0,0355	-0,0090	-0,0080	0,0286	0,0153
G	N233(a490)	0,0346	0,0415	0,0270	0,0736	-0,0385	-0,0260	-0,0365	-0,0064	0,0011	0,0098	0,0091
G	N234(a491)	0,0303	0,0359	0,0270	0,0782	-0,0524	-0,0283	-0,0407	0,0078	-0,0026	0,0874	0,0277
G	N235(a492)	0,0239	0,0282	0,0243	0,0808	-0,0607	-0,0197	-0,0498	0,0213	-0,0060	0,1043	0,0326
G	N236(a493)	0,0324	0,0388	0,0198	0,0751	-0,0330	-0,0067	-0,0456	0,0054	-0,0068	0,0038	0,0027
G	N237(a494)	0,0324	0,0381	0,0283	0,0746	-0,0445	-0,0317	-0,0430	0,0122	0,0029	0,0189	0,0058
G	N238(a495)	0,0235	0,0302	0,0265	0,0819	-0,0619	-0,0347	-0,0533	0,0265	0,0030	0,0835	0,0228
G	N239(a496)	0,0332	0,0405	0,0232	0,0747	-0,0385	-0,0250	-0,0462	0,0166	0,0047	0,0230	0,0042
G	N240(a497)	0,0296	0,0390	0,0268	0,0791	-0,0477	-0,0328	-0,0482	0,0194	0,0117	0,0029	-0,0001
G	N241(a498)	0,0320	0,0415	0,0263	0,0818	-0,0426	-0,0284	-0,0451	0,0024	0,0024	0,0072	0,0042
G	N242(a499)	0,0223	0,0293	0,0265	0,0814	-0,0630	-0,0368	-0,0570	0,0389	0,0087	0,0669	0,0154
G	N243(a500)	0,0370	0,0483	0,0235	0,0767	-0,0241	-0,0160	-0,0380	-0,0113	0,0041	-0,0696	-0,0162
G	N244(a501)	0,0326	0,0434	0,0234	0,0825	-0,0349	-0,0226	-0,0455	0,0078	0,0043	-0,0173	-0,0045
G	N245(a502)	0,0339	0,0449	0,0252	0,0779	-0,0348	-0,0265	-0,0420	0,0043	0,0102	-0,0324	-0,0085
G	N246(a503)	0,0285	0,0380	0,0268	0,0826	-0,0518	-0,0324	-0,0512	0,0201	0,0088	0,0216	0,0049
G	N247(a504)	0,0263	0,0353	0,0265	0,0798	-0,0544	-0,0364	-0,0510	0,0275	0,0120	0,0384	0,0081
G	N248(a505)	0,0372	0,0468	0,0218	0,0766	-0,0252	-0,0121	-0,0422	-0,0024	0,0009	-0,0476	-0,0121
G	N249(a506)	0,0394	0,0516	0,0186	0,0617	0,0018	-0,0045	-0,0207	-0,0354	0,0036	-0,1398	-0,0329
G	N250(a507)	0,0365	0,0482	0,0234	0,0779	-0,0252	-0,0197	-0,0389	-0,0047	0,0067	-0,0579	-0,0144
G	N251(a508)	0,0380	0,0471	0,0197	0,0724	-0,0181	-0,0065	-0,0391	-0,0064	-0,0013	-0,0597	-0,0153
G	N252(a509)	0,0389	0,0513	0,0185	0,0597	0,0028	-0,0060	-0,0188	-0,0355	0,0055	-0,1419	-0,0336
G	N253(a510)	0,0405	0,0507	0,0111	0,0454	0,0242	0,0120	-0,0099	-0,0443	-0,0018	-0,1695	-0,0415
G	N254(a511)	0,0395	0,0517	0,0181	0,0606	0,0036	-0,0031	-0,0197	-0,0370	0,0030	-0,1437	-0,0338
G	N255(a512)	0,0395	0,0496	0,0117	0,0479	0,0184	0,0054	-0,0139	-0,0302	0,0022	-0,1402	-0,0361
B	N55 (a568)	-0,0069	0,0035	-0,0014	0,0063	0,0052	-0,0059	0,0081	-0,0083	0,1251	0,0108	-0,2209
B	N59 (a572)	-0,0047	0,0014	-0,0054	0,0015	-0,0025	0,0066	0,0002	-0,0569	0,2803	0,0169	-0,0702
B	N62 (a575)	0,0019	-0,0064	-0,0007	-0,0109	-0,0150	0,0169	-0,0196	-0,0540	0,2668	-0,0258	0,1681
B	N63 (a576)	-0,0163	0,0380	0,0056	-0,0337	-0,0239	0,0310	-0,0378	-0,0478	0,0199	0,0714	-0,2669
B	N64 (a577)	-0,0090	0,0161	-0,0001	-0,0223	-0,0216	0,0262	-0,0267	-0,0719	0,2622	0,0106	0,0682
B	N65 (a578)	-0,0267	0,0603	0,0086	-0,0508	-0,0354	0,0423	-0,0503	-0,0439	-0,0358	0,0406	-0,0558

Sistema	Nível de Cinza	Componente Principal										
		V1	V2	V3	V4	V5	V6	V7	V8	V9	V10	V11
B	N67 (a580)	-0,0161	0,0286	-0,0014	-0,0249	-0,0224	0,0209	-0,0157	-0,0426	0,1842	-0,0130	0,1176
B	N68 (a581)	-0,0212	0,0450	0,0061	-0,0437	-0,0336	0,0399	-0,0471	-0,0531	0,0740	-0,0050	0,1949
B	N69 (a582)	-0,0291	0,0629	0,0085	-0,0517	-0,0363	0,0422	-0,0495	-0,0452	-0,0191	0,0346	-0,0217
B	N70 (a583)	-0,0317	0,0654	0,0084	-0,0502	-0,0346	0,0360	-0,0408	-0,0241	-0,0334	0,0015	0,0737
B	N71 (a584)	-0,0307	0,0612	0,0087	-0,0498	-0,0369	0,0412	-0,0503	-0,0421	0,0170	0,0241	-0,0725
B	N72 (a585)	-0,0317	0,0652	0,0085	-0,0514	-0,0358	0,0401	-0,0468	-0,0411	-0,0111	0,0297	-0,0382
B	N73 (a586)	-0,0331	0,0665	0,0089	-0,0501	-0,0337	0,0357	-0,0409	-0,0306	-0,0260	0,0146	0,0252
B	N74 (a587)	-0,0320	0,0661	0,0085	-0,0512	-0,0353	0,0394	-0,0456	-0,0385	-0,0199	0,0279	-0,0211
B	N75 (a588)	-0,0319	0,0658	0,0087	-0,0512	-0,0353	0,0394	-0,0462	-0,0365	-0,0280	0,0263	-0,0186
B	N76 (a589)	-0,0337	0,0683	0,0088	-0,0505	-0,0342	0,0356	-0,0405	-0,0277	-0,0241	0,0160	0,0023
B	N77 (a590)	-0,0340	0,0684	0,0087	-0,0497	-0,0337	0,0354	-0,0402	-0,0282	-0,0267	0,0187	-0,0071
B	N78 (a591)	-0,0344	0,0685	0,0088	-0,0496	-0,0333	0,0339	-0,0382	-0,0254	-0,0246	0,0148	0,0003
B	N79 (a592)	-0,0345	0,0689	0,0086	-0,0496	-0,0330	0,0340	-0,0386	-0,0242	-0,0287	0,0157	-0,0028
B	N80 (a593)	-0,0357	0,0696	0,0086	-0,0483	-0,0320	0,0310	-0,0343	-0,0185	-0,0282	0,0093	0,0006
B	N81 (a594)	-0,0357	0,0697	0,0087	-0,0483	-0,0319	0,0307	-0,0338	-0,0175	-0,0294	0,0063	0,0196
B	N82 (a595)	-0,0368	0,0703	0,0086	-0,0471	-0,0308	0,0281	-0,0306	-0,0125	-0,0275	0,0013	0,0209
B	N83 (a596)	-0,0375	0,0707	0,0085	-0,0463	-0,0301	0,0269	-0,0290	-0,0116	-0,0222	0,0036	-0,0011
B	N84 (a597)	-0,0384	0,0709	0,0082	-0,0448	-0,0289	0,0246	-0,0260	-0,0077	-0,0229	-0,0009	0,0074
B	N85 (a598)	-0,0392	0,0711	0,0081	-0,0432	-0,0274	0,0218	-0,0221	-0,0022	-0,0226	-0,0067	0,0212
B	N86 (a599)	-0,0400	0,0713	0,0079	-0,0419	-0,0264	0,0199	-0,0198	0,0002	-0,0207	-0,0082	0,0167
B	N87 (a600)	-0,0408	0,0714	0,0077	-0,0405	-0,0251	0,0181	-0,0175	0,0022	-0,0191	-0,0090	0,0120
B	N88 (a601)	-0,0416	0,0714	0,0075	-0,0389	-0,0237	0,0158	-0,0145	0,0051	-0,0163	-0,0104	0,0085
B	N89 (a602)	-0,0430	0,0711	0,0069	-0,0353	-0,0207	0,0111	-0,0085	0,0119	-0,0146	-0,0165	0,0162
B	N90 (a603)	-0,0439	0,0708	0,0066	-0,0332	-0,0192	0,0086	-0,0053	0,0148	-0,0132	-0,0193	0,0213
B	N91 (a604)	-0,0452	0,0705	0,0060	-0,0301	-0,0166	0,0053	-0,0012	0,0178	-0,0092	-0,0198	0,0145
B	N92 (a605)	-0,0465	0,0697	0,0053	-0,0261	-0,0134	0,0012	0,0040	0,0220	-0,0082	-0,0232	0,0217
B	N93 (a606)	-0,0479	0,0690	0,0045	-0,0224	-0,0104	-0,0023	0,0082	0,0241	-0,0040	-0,0230	0,0159
B	N94 (a607)	-0,0489	0,0679	0,0038	-0,0186	-0,0075	-0,0059	0,0128	0,0276	-0,0021	-0,0255	0,0202
B	N95 (a608)	-0,0499	0,0668	0,0030	-0,0149	-0,0045	-0,0093	0,0169	0,0300	0,0010	-0,0255	0,0158
B	N96 (a609)	-0,0508	0,0656	0,0022	-0,0109	-0,0014	-0,0129	0,0215	0,0325	0,0034	-0,0263	0,0172
B	N97 (a610)	-0,0516	0,0641	0,0013	-0,0071	0,0017	-0,0164	0,0256	0,0345	0,0056	-0,0266	0,0182
B	N98 (a611)	-0,0525	0,0627	0,0004	-0,0032	0,0047	-0,0190	0,0286	0,0348	0,0067	-0,0250	0,0162
B	N99 (a612)	-0,0532	0,0608	-0,0006	0,0010	0,0078	-0,0221	0,0322	0,0362	0,0083	-0,0248	0,0148
B	N100(a613)	-0,0538	0,0583	-0,0019	0,0062	0,0118	-0,0256	0,0362	0,0366	0,0107	-0,0220	0,0107
B	N101(a614)	-0,0545	0,0559	-0,0032	0,0110	0,0154	-0,0279	0,0387	0,0352	0,0115	-0,0193	0,0107
B	N102(a615)	-0,0551	0,0525	-0,0049	0,0170	0,0196	-0,0305	0,0415	0,0331	0,0131	-0,0156	0,0074
B	N103(a616)	-0,0555	0,0491	-0,0066	0,0227	0,0239	-0,0322	0,0431	0,0300	0,0138	-0,0106	0,0040
B	N104(a617)	-0,0558	0,0448	-0,0088	0,0292	0,0285	-0,0339	0,0447	0,0261	0,0157	-0,0056	-0,0002
B	N105(a618)	-0,0560	0,0407	-0,0108	0,0349	0,0324	-0,0341	0,0446	0,0206	0,0154	-0,0005	-0,0015
B	N106(a619)	-0,0559	0,0366	-0,0132	0,0401	0,0359	-0,0336	0,0435	0,0147	0,0153	0,0054	-0,0046
B	N107(a620)	-0,0558	0,0325	-0,0155	0,0447	0,0388	-0,0322	0,0416	0,0078	0,0137	0,0103	-0,0057
B	N108(a621)	-0,0557	0,0288	-0,0181	0,0487	0,0411	-0,0297	0,0384	0,0002	0,0121	0,0158	-0,0079
B	N109(a622)	-0,0554	0,0247	-0,0209	0,0524	0,0430	-0,0270	0,0351	-0,0070	0,0090	0,0202	-0,0057
B	N110(a623)	-0,0546	0,0202	-0,0242	0,0562	0,0448	-0,0234	0,0308	-0,0150	0,0062	0,0248	-0,0079
B	N111(a624)	-0,0535	0,0150	-0,0279	0,0597	0,0465	-0,0176	0,0245	-0,0243	0,0019	0,0308	-0,0076

Sistema	Nível de Cinza	Componente Principal										
		V1	V2	V3	V4	V5	V6	V7	V8	V9	V10	V11
B	N113(a626)	-0,0496	0,0022	-0,0366	0,0656	0,0480	-0,0034	0,0086	-0,0449	-0,0066	0,0394	-0,0055
B	N114(a627)	-0,0465	-0,0051	-0,0410	0,0672	0,0478	0,0062	-0,0018	-0,0551	-0,0112	0,0431	-0,0055
B	N115(a628)	-0,0422	-0,0134	-0,0459	0,0673	0,0469	0,0169	-0,0144	-0,0652	-0,0155	0,0458	-0,0034
B	N116(a629)	-0,0361	-0,0225	-0,0500	0,0660	0,0451	0,0291	-0,0288	-0,0736	-0,0188	0,0477	-0,0004
B	N117(a630)	-0,0282	-0,0322	-0,0536	0,0612	0,0404	0,0423	-0,0451	-0,0825	-0,0245	0,0473	0,0064
B	N118(a631)	-0,0187	-0,0415	-0,0551	0,0543	0,0339	0,0554	-0,0600	-0,0843	-0,0270	0,0435	0,0115
B	N119(a632)	-0,0087	-0,0494	-0,0530	0,0458	0,0267	0,0660	-0,0722	-0,0840	-0,0266	0,0386	0,0118
B	N120(a633)	0,0016	-0,0551	-0,0503	0,0350	0,0168	0,0729	-0,0809	-0,0794	-0,0263	0,0267	0,0155
B	N121(a634)	0,0115	-0,0588	-0,0450	0,0222	0,0063	0,0775	-0,0872	-0,0683	-0,0271	0,0160	0,0191
B	N122(a635)	0,0208	-0,0610	-0,0377	0,0092	-0,0035	0,0784	-0,0887	-0,0559	-0,0231	0,0017	0,0199
B	N123(a636)	0,0287	-0,0606	-0,0302	-0,0023	-0,0135	0,0752	-0,0871	-0,0419	-0,0201	-0,0092	0,0179
B	N124(a637)	0,0353	-0,0592	-0,0213	-0,0127	-0,0214	0,0701	-0,0824	-0,0281	-0,0167	-0,0209	0,0158
B	N125(a638)	0,0411	-0,0561	-0,0132	-0,0222	-0,0284	0,0632	-0,0744	-0,0134	-0,0128	-0,0288	0,0134
B	N126(a639)	0,0449	-0,0525	-0,0056	-0,0307	-0,0346	0,0528	-0,0672	-0,0005	-0,0086	-0,0385	0,0097
B	N127(a640)	0,0479	-0,0482	0,0024	-0,0365	-0,0401	0,0446	-0,0566	0,0117	-0,0051	-0,0442	0,0060
B	N128(a641)	0,0500	-0,0443	0,0093	-0,0413	-0,0431	0,0357	-0,0471	0,0200	0,0002	-0,0444	0,0030
B	N129(a642)	0,0516	-0,0400	0,0151	-0,0444	-0,0458	0,0274	-0,0370	0,0294	0,0015	-0,0432	-0,0012
B	N130(a643)	0,0524	-0,0363	0,0211	-0,0467	-0,0473	0,0180	-0,0284	0,0354	0,0042	-0,0419	-0,0051
B	N131(a644)	0,0529	-0,0325	0,0258	-0,0479	-0,0485	0,0096	-0,0196	0,0394	0,0065	-0,0381	-0,0081
B	N132(a645)	0,0531	-0,0290	0,0299	-0,0489	-0,0484	0,0018	-0,0116	0,0421	0,0070	-0,0340	-0,0115
B	N133(a646)	0,0533	-0,0255	0,0337	-0,0487	-0,0484	-0,0057	-0,0049	0,0434	0,0079	-0,0276	-0,0135
B	N134(a647)	0,0533	-0,0224	0,0366	-0,0484	-0,0480	-0,0127	0,0015	0,0425	0,0084	-0,0219	-0,0157
B	N135(a648)	0,0533	-0,0193	0,0391	-0,0480	-0,0466	-0,0195	0,0076	0,0398	0,0086	-0,0140	-0,0171
B	N136(a649)	0,0537	-0,0156	0,0414	-0,0463	-0,0450	-0,0246	0,0133	0,0355	0,0089	-0,0051	-0,0164
B	N137(a650)	0,0541	-0,0123	0,0430	-0,0451	-0,0424	-0,0286	0,0186	0,0306	0,0075	0,0029	-0,0169
B	N138(a651)	0,0543	-0,0091	0,0443	-0,0438	-0,0397	-0,0327	0,0232	0,0250	0,0070	0,0092	-0,0163
B	N139(a652)	0,0547	-0,0059	0,0453	-0,0414	-0,0376	-0,0359	0,0262	0,0190	0,0063	0,0176	-0,0150
B	N140(a653)	0,0548	-0,0033	0,0459	-0,0408	-0,0341	-0,0384	0,0306	0,0119	0,0059	0,0265	-0,0122
B	N141(a654)	0,0553	0,0002	0,0459	-0,0386	-0,0307	-0,0405	0,0339	0,0032	0,0040	0,0336	-0,0097
B	N142(a655)	0,0560	0,0039	0,0459	-0,0361	-0,0268	-0,0414	0,0363	-0,0041	0,0020	0,0390	-0,0075
B	N143(a656)	0,0565	0,0074	0,0452	-0,0344	-0,0219	-0,0417	0,0401	-0,0142	0,0001	0,0462	-0,0042
B	N144(a657)	0,0567	0,0104	0,0446	-0,0321	-0,0177	-0,0418	0,0423	-0,0238	-0,0016	0,0566	0,0018
B	N145(a658)	0,0573	0,0142	0,0432	-0,0297	-0,0120	-0,0406	0,0437	-0,0321	-0,0014	0,0591	0,0054
B	N146(a659)	0,0572	0,0169	0,0419	-0,0278	-0,0076	-0,0388	0,0467	-0,0421	-0,0052	0,0649	0,0096
B	N147(a660)	0,0577	0,0202	0,0401	-0,0252	-0,0026	-0,0367	0,0461	-0,0477	-0,0046	0,0657	0,0129
B	N148(a661)	0,0578	0,0230	0,0381	-0,0232	0,0024	-0,0337	0,0469	-0,0548	-0,0051	0,0634	0,0150
B	N149(a662)	0,0580	0,0259	0,0362	-0,0204	0,0073	-0,0315	0,0451	-0,0596	-0,0072	0,0651	0,0181
B	N150(a663)	0,0578	0,0281	0,0339	-0,0196	0,0133	-0,0286	0,0454	-0,0649	-0,0099	0,0605	0,0180
B	N151(a664)	0,0579	0,0310	0,0316	-0,0168	0,0184	-0,0248	0,0437	-0,0685	-0,0122	0,0508	0,0171
B	N152(a665)	0,0576	0,0325	0,0284	-0,0170	0,0250	-0,0205	0,0421	-0,0726	-0,0129	0,0463	0,0190
B	N153(a666)	0,0573	0,0340	0,0255	-0,0157	0,0294	-0,0158	0,0407	-0,0762	-0,0125	0,0427	0,0212
B	N154(a667)	0,0571	0,0352	0,0242	-0,0147	0,0329	-0,0126	0,0393	-0,0773	-0,0133	0,0334	0,0195
B	N155(a668)	0,0570	0,0351	0,0213	-0,0162	0,0379	-0,0078	0,0362	-0,0757	-0,0158	0,0322	0,0206
B	N156(a669)	0,0569	0,0361	0,0202	-0,0161	0,0400	-0,0058	0,0372	-0,0741	-0,0147	0,0243	0,0171
B	N157(a670)	0,0568	0,0366	0,0193	-0,0144	0,0412	-0,0043	0,0329	-0,0739	-0,0157	0,0252	0,0198

Sistema	Nível de Cinza	Componente Principal										
		V1	V2	V3	V4	V5	V6	V7	V8	V9	V10	V11
B	N159(a672)	0,0564	0,0386	0,0159	-0,0125	0,0470	0,0009	0,0282	-0,0710	-0,0168	-0,0063	0,0103
B	N160(a673)	0,0560	0,0391	0,0131	-0,0134	0,0513	0,0038	0,0253	-0,0677	-0,0152	-0,0137	0,0093
B	N161(a674)	0,0548	0,0386	0,0105	-0,0139	0,0559	0,0093	0,0231	-0,0698	-0,0152	-0,0191	0,0112
B	N162(a675)	0,0547	0,0411	0,0076	-0,0131	0,0597	0,0089	0,0200	-0,0574	-0,0110	-0,0205	0,0056
B	N163(a676)	0,0539	0,0417	0,0039	-0,0125	0,0634	0,0139	0,0158	-0,0513	-0,0083	-0,0306	0,0035
B	N164(a677)	0,0538	0,0407	0,0035	-0,0142	0,0644	0,0131	0,0150	-0,0521	-0,0113	-0,0195	0,0065
B	N165(a678)	0,0539	0,0417	0,0001	-0,0131	0,0650	0,0150	0,0118	-0,0434	-0,0103	-0,0166	0,0062
B	N166(a679)	0,0536	0,0424	-0,0021	-0,0116	0,0672	0,0175	0,0069	-0,0331	-0,0103	-0,0227	0,0010
B	N167(a680)	0,0528	0,0424	-0,0042	-0,0120	0,0697	0,0176	0,0025	-0,0302	-0,0076	-0,0205	0,0023
B	N168(a681)	0,0526	0,0430	-0,0067	-0,0100	0,0692	0,0214	-0,0022	-0,0167	-0,0041	-0,0271	-0,0007
B	N169(a682)	0,0519	0,0430	-0,0087	-0,0100	0,0714	0,0213	-0,0098	-0,0050	0,0015	-0,0153	0,0026
B	N170(a683)	0,0511	0,0438	-0,0109	-0,0096	0,0717	0,0224	-0,0063	-0,0080	-0,0035	-0,0350	-0,0055
B	N171(a684)	0,0501	0,0417	-0,0145	-0,0124	0,0737	0,0229	-0,0152	0,0109	0,0043	-0,0022	0,0038
B	N172(a685)	0,0506	0,0409	-0,0132	-0,0128	0,0726	0,0234	-0,0191	0,0219	0,0059	0,0011	0,0023
B	N173(a686)	0,0487	0,0409	-0,0173	-0,0099	0,0727	0,0267	-0,0262	0,0340	0,0047	-0,0010	-0,0012
B	N174(a687)	0,0487	0,0392	-0,0171	-0,0135	0,0731	0,0265	-0,0290	0,0417	0,0094	-0,0026	-0,0022
B	N175(a688)	0,0470	0,0389	-0,0248	-0,0126	0,0703	0,0252	-0,0360	0,0643	0,0158	0,0226	0,0030
B	N176(a689)	0,0488	0,0395	-0,0240	-0,0135	0,0698	0,0251	-0,0301	0,0483	0,0127	0,0189	0,0044
B	N177(a690)	0,0473	0,0370	-0,0299	-0,0155	0,0672	0,0246	-0,0367	0,0647	0,0131	0,0198	0,0014
B	N178(a691)	0,0449	0,0364	-0,0330	-0,0169	0,0671	0,0201	-0,0393	0,0757	0,0203	0,0277	0,0005
B	N179(a692)	0,0457	0,0380	-0,0374	-0,0118	0,0618	0,0213	-0,0419	0,0764	0,0149	0,0166	-0,0034
B	N180(a693)	0,0460	0,0389	-0,0314	-0,0143	0,0671	0,0190	-0,0377	0,0720	0,0244	0,0230	-0,0001
B	N181(a694)	0,0418	0,0349	-0,0404	-0,0170	0,0654	0,0153	-0,0480	0,0894	0,0229	0,0391	-0,0005
B	N182(a695)	0,0431	0,0365	-0,0413	-0,0142	0,0624	0,0185	-0,0462	0,0823	0,0221	0,0254	-0,0008
B	N183(a696)	0,0416	0,0345	-0,0460	-0,0183	0,0601	0,0213	-0,0365	0,0910	0,0221	0,0431	-0,0011
B	N184(a697)	0,0440	0,0367	-0,0571	-0,0156	0,0465	0,0014	-0,0341	0,0577	0,0148	0,0168	-0,0046
B	N185(a698)	0,0446	0,0359	-0,0571	-0,0153	0,0441	0,0034	-0,0359	0,0635	0,0126	0,0153	-0,0053
B	N186(a699)	0,0446	0,0374	-0,0588	-0,0119	0,0418	0,0030	-0,0327	0,0541	0,0008	0,0021	-0,0106
B	N187(a700)	0,0428	0,0341	-0,0648	-0,0183	0,0378	-0,0031	-0,0269	0,0522	0,0100	0,0195	-0,0037
B	N188(a701)	0,0402	0,0326	-0,0747	-0,0140	0,0220	-0,0114	-0,0277	0,0426	0,0237	0,0076	-0,0010
B	N189(a702)	0,0392	0,0288	-0,0789	-0,0193	0,0110	-0,0280	-0,0230	0,0304	0,0030	-0,0058	-0,0093
B	N190(a703)	0,0364	0,0273	-0,0775	-0,0131	0,0113	-0,0102	-0,0277	0,0707	0,0067	0,0678	0,0049
B	N191(a704)	0,0339	0,0266	-0,0822	-0,0113	0,0022	-0,0230	-0,0319	0,0617	0,0093	0,0429	-0,0016
B	N192(a705)	0,0340	0,0250	-0,0861	-0,0177	-0,0048	-0,0367	-0,0162	0,0214	0,0083	0,0083	-0,0034
B	N193(a706)	0,0281	0,0184	-0,0905	-0,0157	-0,0235	-0,0396	-0,0102	0,0235	-0,0094	0,0262	-0,0035
B	N194(a707)	0,0301	0,0194	-0,0898	-0,0194	-0,0111	-0,0272	-0,0137	0,0334	0,0149	0,0407	0,0067
B	N195(a708)	0,0280	0,0181	-0,0927	-0,0192	-0,0175	-0,0283	-0,0010	0,0207	0,0035	0,0298	0,0011
B	N196(a709)	0,0223	0,0131	-0,0931	-0,0185	-0,0314	-0,0510	-0,0040	0,0007	-0,0022	0,0327	0,0065
B	N197(a710)	0,0224	0,0133	-0,0931	-0,0174	-0,0361	-0,0490	0,0022	-0,0135	-0,0007	0,0092	0,0044
B	N198(a711)	0,0239	0,0143	-0,0929	-0,0143	-0,0380	-0,0362	0,0143	-0,0126	-0,0079	0,0081	0,0006
B	N199(a712)	0,0208	0,0130	-0,0925	-0,0110	-0,0434	-0,0489	0,0060	-0,0217	-0,0153	-0,0123	-0,0059
B	N200(a713)	0,0223	0,0136	-0,0921	-0,0133	-0,0405	-0,0475	0,0080	-0,0267	-0,0042	-0,0070	0,0014
B	N201(a714)	0,0204	0,0132	-0,0919	-0,0103	-0,0450	-0,0486	0,0098	-0,0260	-0,0235	-0,0146	-0,0069
B	N202(a715)	0,0188	0,0100	-0,0922	-0,0091	-0,0520	-0,0345	0,0227	-0,0238	-0,0170	-0,0110	-0,0053
B	N203(a716)	0,0187	0,0110	-0,0935	-0,0098	-0,0496	-0,0374	0,0166	-0,0225	-0,0054	-0,0099	-0,0007

Sistema	Nível de Cinza	Componente Principal										
		V1	V2	V3	V4	V5	V6	V7	V8	V9	V10	V11
B	N205(a718)	0,0183	0,0104	-0,0900	-0,0094	-0,0528	-0,0539	0,0115	-0,0283	-0,0199	-0,0128	-0,0057
B	N206(a719)	0,0181	0,0097	-0,0907	-0,0086	-0,0561	-0,0278	0,0326	-0,0364	-0,0027	-0,0251	0,0005
B	N207(a720)	0,0182	0,0095	-0,0923	-0,0081	-0,0562	-0,0252	0,0310	-0,0265	-0,0023	-0,0120	0,0004
B	N208(a721)	0,0196	0,0121	-0,0898	-0,0063	-0,0546	-0,0324	0,0293	-0,0428	-0,0030	-0,0268	0,0015
B	N209(a722)	0,0167	0,0095	-0,0901	-0,0069	-0,0567	-0,0440	0,0185	-0,0426	-0,0036	-0,0274	0,0009
B	N210(a723)	0,0187	0,0117	-0,0893	-0,0037	-0,0562	-0,0433	0,0151	-0,0421	0,0001	-0,0196	0,0043
B	N211(a724)	0,0165	0,0094	-0,0909	-0,0080	-0,0561	-0,0304	0,0319	-0,0380	-0,0094	-0,0414	-0,0076
B	N212(a725)	0,0185	0,0110	-0,0876	-0,0002	-0,0614	-0,0252	0,0316	-0,0441	-0,0129	-0,0208	0,0018
B	N213(a726)	0,0163	0,0083	-0,0890	-0,0039	-0,0622	-0,0249	0,0357	-0,0298	-0,0259	-0,0289	-0,0113
B	N214(a727)	0,0211	0,0124	-0,0867	0,0034	-0,0636	-0,0007	0,0455	-0,0306	0,0011	-0,0182	0,0032
B	N215(a728)	0,0233	0,0134	-0,0536	0,0194	-0,0578	0,0915	0,0865	0,0187	0,0464	0,0074	0,0129
B	N216(a729)	0,0225	0,0137	-0,0699	0,0200	-0,0713	0,0487	0,0685	-0,0001	0,0165	0,0051	0,0082
B	N217(a730)	0,0216	0,0148	-0,0262	0,0307	-0,0443	0,1246	0,0942	0,0261	0,0342	-0,0222	-0,0002
B	N218(a731)	0,0196	0,0126	-0,0255	0,0287	-0,0459	0,1249	0,1004	0,0174	0,0518	0,0133	0,0175
B	N219(a732)	0,0343	0,0323	-0,0025	0,0509	-0,0279	0,1088	0,0741	0,0221	-0,0086	-0,0022	-0,0085
B	N220(a733)	0,0169	0,0102	-0,0136	0,0347	-0,0378	0,1348	0,0933	0,0438	-0,0113	0,0359	-0,0007
B	N221(a734)	0,0206	0,0117	-0,0178	0,0299	-0,0392	0,1338	0,1020	0,0359	-0,0135	0,0301	-0,0029
B	N222(a735)	0,0247	0,0170	-0,0074	0,0393	-0,0402	0,1275	0,0935	0,0347	-0,0125	0,0355	-0,0017
B	N223(a736)	0,0345	0,0308	-0,0023	0,0351	-0,0139	0,1066	0,0905	0,0019	-0,0130	-0,0301	-0,0182
B	N224(a737)	0,0197	0,0124	-0,0097	0,0364	-0,0445	0,1271	0,0947	0,0530	-0,0080	0,0591	0,0001
B	N225(a738)	0,0264	0,0214	-0,0044	0,0488	-0,0384	0,1160	0,0727	0,0240	-0,0165	0,0297	0,0025
B	N226(a739)	0,0312	0,0299	-0,0039	0,0314	-0,0072	0,1028	0,0816	0,0030	-0,0035	-0,1218	-0,0452
B	N227(a740)	0,0312	0,0281	0,0092	0,0657	-0,0537	0,0647	0,0337	0,0422	-0,0096	0,1011	0,0203
B	N228(a741)	0,0396	0,0402	0,0154	0,0709	-0,0423	0,0481	0,0255	0,0090	-0,0110	0,0310	0,0036
B	N229(a742)	0,0350	0,0400	0,0177	0,0754	-0,0351	0,0121	-0,0270	0,0091	-0,0076	-0,0016	-0,0021
B	N230(a743)	0,0310	0,0367	0,0241	0,0801	-0,0476	-0,0144	-0,0415	0,0058	-0,0069	0,0712	0,0250
B	N231(a744)	0,0377	0,0450	0,0239	0,0748	-0,0278	-0,0066	-0,0266	-0,0217	-0,0086	0,0009	0,0090
B	N232(a745)	0,0338	0,0415	0,0238	0,0807	-0,0372	-0,0112	-0,0355	-0,0090	-0,0080	0,0286	0,0153
B	N233(a746)	0,0346	0,0415	0,0270	0,0736	-0,0385	-0,0260	-0,0365	-0,0064	0,0011	0,0098	0,0091
B	N234(a747)	0,0303	0,0359	0,0270	0,0782	-0,0524	-0,0283	-0,0407	0,0078	-0,0026	0,0874	0,0277
B	N235(a748)	0,0239	0,0282	0,0243	0,0808	-0,0607	-0,0197	-0,0498	0,0213	-0,0060	0,1043	0,0326
B	N236(a749)	0,0324	0,0388	0,0198	0,0751	-0,0330	-0,0067	-0,0456	0,0054	-0,0068	0,0038	0,0027
B	N237(a750)	0,0324	0,0381	0,0283	0,0746	-0,0445	-0,0317	-0,0430	0,0122	0,0029	0,0189	0,0058
B	N238(a751)	0,0235	0,0302	0,0265	0,0819	-0,0619	-0,0347	-0,0533	0,0265	0,0030	0,0835	0,0228
B	N239(a752)	0,0332	0,0405	0,0232	0,0747	-0,0385	-0,0250	-0,0462	0,0166	0,0047	0,0230	0,0042
B	N240(a753)	0,0296	0,0390	0,0268	0,0791	-0,0477	-0,0328	-0,0482	0,0194	0,0117	0,0029	-0,0001
B	N241(a754)	0,0320	0,0415	0,0263	0,0818	-0,0426	-0,0284	-0,0451	0,0024	0,0024	0,0072	0,0042
B	N242(a755)	0,0223	0,0293	0,0265	0,0814	-0,0630	-0,0368	-0,0570	0,0389	0,0087	0,0669	0,0154
B	N243(a756)	0,0370	0,0483	0,0235	0,0767	-0,0241	-0,0160	-0,0380	-0,0113	0,0041	-0,0696	-0,0162
B	N244(a757)	0,0326	0,0434	0,0234	0,0825	-0,0349	-0,0226	-0,0455	0,0078	0,0043	-0,0173	-0,0045
B	N245(a758)	0,0339	0,0449	0,0252	0,0779	-0,0348	-0,0265	-0,0420	0,0043	0,0102	-0,0324	-0,0085
B	N246(a759)	0,0285	0,0380	0,0268	0,0826	-0,0518	-0,0324	-0,0512	0,0201	0,0088	0,0216	0,0049
B	N247(a760)	0,0263	0,0353	0,0265	0,0798	-0,0544	-0,0364	-0,0510	0,0275	0,0120	0,0384	0,0081
B	N248(a761)	0,0372	0,0468	0,0218	0,0766	-0,0252	-0,0121	-0,0422	-0,0024	0,0009	-0,0476	-0,0121
B	N249(a762)	0,0394	0,0516	0,0186	0,0617	0,0018	-0,0045	-0,0207	-0,0354	0,0036	-0,1398	-0,0329

Sistema	Nível de Cinza	Componente Principal										
		V1	V2	V3	V4	V5	V6	V7	V8	V9	V10	V11
B	N251(a764)	0,0380	0,0471	0,0197	0,0724	-0,0181	-0,0065	-0,0391	-0,0064	-0,0013	-0,0597	-0,0153
B	N252(a765)	0,0389	0,0513	0,0185	0,0597	0,0028	-0,0060	-0,0188	-0,0355	0,0055	-0,1419	-0,0336
B	N253(a766)	0,0405	0,0507	0,0111	0,0454	0,0242	0,0120	-0,0099	-0,0443	-0,0018	-0,1695	-0,0415
B	N254(a767)	0,0395	0,0517	0,0181	0,0606	0,0036	-0,0031	-0,0197	-0,0370	0,0030	-0,1437	-0,0338
B	N255(a768)	0,0395	0,0496	0,0117	0,0479	0,0184	0,0054	-0,0139	-0,0302	0,0022	-0,1402	-0,0361
Autovalor		190,71	102,39	83,99	56,26	49,08	26,34	22,91	11,79	8,60	6,32	4,82
%Variância Explicada		32,43	17,41	14,29	9,57	8,35	4,48	3,90	2,01	1,46	1,08	0,82
%Variância Acumulada		32,43	49,84	64,13	73,70	82,05	86,53	90,43	92,44	93,90	94,98	95,80

# Livros Grátis

( <http://www.livrosgratis.com.br> )

Milhares de Livros para Download:

[Baixar livros de Administração](#)

[Baixar livros de Agronomia](#)

[Baixar livros de Arquitetura](#)

[Baixar livros de Artes](#)

[Baixar livros de Astronomia](#)

[Baixar livros de Biologia Geral](#)

[Baixar livros de Ciência da Computação](#)

[Baixar livros de Ciência da Informação](#)

[Baixar livros de Ciência Política](#)

[Baixar livros de Ciências da Saúde](#)

[Baixar livros de Comunicação](#)

[Baixar livros do Conselho Nacional de Educação - CNE](#)

[Baixar livros de Defesa civil](#)

[Baixar livros de Direito](#)

[Baixar livros de Direitos humanos](#)

[Baixar livros de Economia](#)

[Baixar livros de Economia Doméstica](#)

[Baixar livros de Educação](#)

[Baixar livros de Educação - Trânsito](#)

[Baixar livros de Educação Física](#)

[Baixar livros de Engenharia Aeroespacial](#)

[Baixar livros de Farmácia](#)

[Baixar livros de Filosofia](#)

[Baixar livros de Física](#)

[Baixar livros de Geociências](#)

[Baixar livros de Geografia](#)

[Baixar livros de História](#)

[Baixar livros de Línguas](#)



[Baixar livros de Literatura](#)  
[Baixar livros de Literatura de Cordel](#)  
[Baixar livros de Literatura Infantil](#)  
[Baixar livros de Matemática](#)  
[Baixar livros de Medicina](#)  
[Baixar livros de Medicina Veterinária](#)  
[Baixar livros de Meio Ambiente](#)  
[Baixar livros de Meteorologia](#)  
[Baixar Monografias e TCC](#)  
[Baixar livros Multidisciplinar](#)  
[Baixar livros de Música](#)  
[Baixar livros de Psicologia](#)  
[Baixar livros de Química](#)  
[Baixar livros de Saúde Coletiva](#)  
[Baixar livros de Serviço Social](#)  
[Baixar livros de Sociologia](#)  
[Baixar livros de Teologia](#)  
[Baixar livros de Trabalho](#)  
[Baixar livros de Turismo](#)