Apêndice A

Classificação de Texturas a partir de Transformações Morfológicas

Uma ferramenta morfológica para classificação automática de texturas é proposta e aplicada a um enorme conjunto de amostras de revestimento de paredes. Começando a partir de medidas de dados morfológicos (covariança, velocidade de erosão e dilatação, distribuição de tamanho, densidade de picos e vales) sobre imagens em níveis de cinza, uma análise de correspondência é usada para aprender um procedimento de visualização de superfícies em um espaço reduzido, e, assim, selecionar as medidas mais pertinentes com respeito à classificação de texturas.

A.1 Introdução

A classificação de textura por análise de imagens tem muitas aplicações na indústria. O principal objetivo deste estudo é fornecer e demonstrar a utilidade de um algoritmo de classificação de textura que usa algumas medidas morfológicas e análise de dados estatísticos (análise de correspondência) para classificar texturas aleatórias em k diferentes classes. Isto é aplicado para o desenvolvimento de um algoritmo rápido para classificar automaticamente algumas amostras de revestimento de paredes, para, posteriormente, usá-lo como um procedimento de inspeção visual em larga escala.

Este trabalho está dividido em dois passos: treinamento e classificação. No passo do treinamento, as medidas morfológicas feitas sobre imagens das amostras produzem uma enorme quantidade de dados, que são submetidos a uma análise estatítica para conseguir a melhor separação de representação de pontos em k regiões. O passo de classificação é obtido pela projeção experimental de dados em uma dimensão menor que representa um sub-espaço dos dados medidos.

A principal dificuldade é encontrar as melhores medidas morfológicas que devem ser executadas. Neste trabalho, mostraremos que as medidas morfológicas: (i) curva de

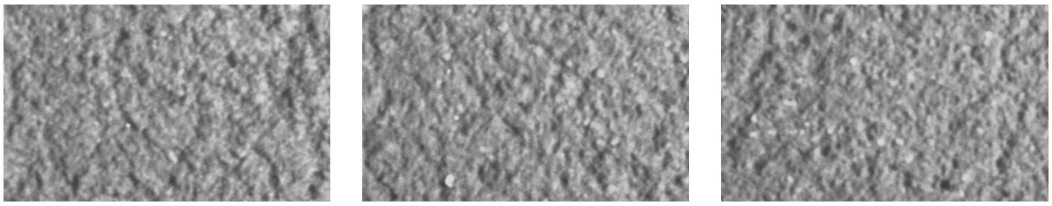

(a) (b) (c)

Figura A.1: (a) Qualidade $Q1$ ("too early"), (b) Qualidade $Q2$ ("normal"), (c) Qualidade $Q3$ ("too late").

covariança; (*ii*) curvas de dilatação e erosão; e (*iii*) distribuição granulométrica e anti-granulométrica não fornecem a mesma precisão para a classificação. Mostraremos como extrair as melhores funções morfológicas e os valores mais discriminantes para uma boa classificação das amostras. Este apêndice está organizado da seguinte forma. A Seção A.2 descreve as amostras estudadas. A Seção A.3 apresenta as medidas morfológicas utilizadas neste trabalho. A Seção A.4 descreve a análise estatística de dados. A Seção A.5 apresenta os resultados experimentais e finalmente, as conclusões estão resumidas na Seção A.6.

A.2 Amostras e Aquisição de Imagens

As amostras de revestimento de paredes estudadas neste trabalho são colocadas em um catálogo para serem dados aos clientes da indústria. As amostras produzidas apresentam três tipos de qualidades de texturas (denotadas por $Q1$, $Q2$ e $Q3$), devido a alguma instabilidade na elaboração destas texturas. Estas qualidades dependem do tempo de secagem do cimento antes de ser raspado. É possível definir as seguintes categorias, a partir do aspecto morfológico das amostras: "too early", "normal" e "too late". Alguns exemplos de tais amostras estão apresentados na Figura A.1

O problema de classificação estudado aqui é, dado uma coleção de imagens das amostras de um grupo G contendo diferentes tipos de texturas, classificá-las em classes $Q1$, $Q2$ e $Q3$, segundo o tipo de texturas.

Neste trabalho, apresentaremos um estudo com 300 imagens de amostras.

No processo de aquisição de imagens das amostras de revestimento de parede, um dispositivo simples composto por uma câmera e duas lâmpadas foram usadas. Uma iluminação normal e isotrópica incide obliquamente a 45 graus. As sombras, que o revelo da amostra projetam, fornecem uma textura não isotrópica. Nas imagens, os níveis de cinza não representam diretamente a elevação do ponto considerado, mas são, no entanto, representantes da topografia: as imagens obtidas apresentam sombras, devido a presença forte de relevos (Figura A.1).

Todas imagens adquiridas apresentaram um ruído periódico horizontal, que foi removido por um filtro de freqüência, usando a Transformação Rápida de Fourier (TRF). As imagens finais contêm 485×285 pixels.

A.3 Medidas Morfológicas

Quando se trabalha com texturas, é conveniente considar as imagens como realizações de estruturas aleatórias (conjuntos aleatórios no caso de imagens binárias [32, 41], e funções aleatórias para imagens em níveis de cinza). Estas estruturas aleatórias podem ser caracterizados pela capacidade de Choquet [32, 41, 25], a partir do qual são derivados a maioria das medidas morfológicas.

A.3.1 A Capacidade de Choquet

Uma função aleatória, semicontínua, limitada superiormente $Z(x)$ é caracterizada pela sua capacidade de Choquet, $T(g)$, que pode ser definida [25] sobre funções contínuas limitadas inferiormente g com um suporte compacto K:

$$T(g) = P\{x \in D_Z(g)\};\ D_Z(g)^c = \{x, Z(y) < g(y-x), \forall y \in K\} \tag{A.1}$$

Um caso particular e muito utilizado é a lei espacial definida sobre um número finito de pontos $x_1, x_2, ..., x_n$ da seguinte forma,

$$F(x_1, x_2, ..., x_n, z_1, z_2, ..., z_n) = P\{Z(x_1) < z_1, Z(x_2) < z_2, ..., Z(x_n) < z_n\} \tag{A.2}$$

Outros casos particulares fornecem as transformações por $\vee$ (supremo), chamado uma dilatação ou por $\wedge$ (ínfimo), chamado uma erosão, que geram novas funções aleatórias:

$$Z_\vee(K) = \vee_{x \in K}\{Z(x)\} = Z \oplus K$$

$$Z_\wedge(K) = \wedge_{x \in K}\{Z(x)\} = Z \ominus K$$

Como um caso particular, quando o conjunto compacto K é limitado no ponto x e $g(x) = z$, recobrimos a função distribuição $F(z)$:

$$F(z) = P\{Z(x) < z\} = 1 - T(g) \tag{A.3}$$

A.3.2 Medidas Morfológicas

A.3.2.1 Função de Covariança

A função de covariança centrada e reduzida de uma função aleatória estacionária $Z(x)$ é definida por:

$$C(h) = \frac{E\{Z(x)Z(x+h)\} - (E\{Z(x)\})^2}{E\{Z(x)Z(x)\} - (E\{Z(x)\})^2}$$

onde, $E\{\cdot\}$ denota a esperança matemática de uma variável aleatória. O termo $E\{Z(x)$ $Z(x+h)\}$ é estimado pela média do produto $\{Z(x)Z(x+h)\}$ sobre os pixels das imagens. Como este produto pode ser interpretado em termos de um produto de convolução, ele é obtido por TRF. Adicionamos o valor 0.5 para a covariança centrada e reduzida, dessa forma, evitando valores negativos para a análise de correspondência. As medidas foram feitas por valores h entre 1 to 100 nas duas principais direções da imagem (horizontal e vertical).

A.3.2.2 Curva de Abertura e Fechamento (Antigranulometria e Granulometria)

Uma granulometria é o estudo de distribuições de tamanho dos objetos em uma imagem [32, 41]. Calculamos, ao mesmo tempo, uma granulometria (distribuições de tamanhos de picos) usando aberturas morfológicas e uma antigranulometria (distribuições de tamanhos de vales) usando fechamentos morfológicos. O seguinte estimador para a densidade de tamanhos é equivalente a uma função de densidade de probabilidade, enquanto a função $S(k)$ tem o papel de uma função distribuição acumulativa [23]:

$$\tilde{S} = S(k) - S(k+1)$$

com,

$$S(k) = \frac{1}{N} \cdot \frac{1}{\mathsf{Vol}\{M \ominus 2kB\}} \cdot \begin{cases} \mathsf{Vol}\{(M \ominus 2kB) \cap ((Z - \mathsf{Av}\{Z\}) \circ kB)\} & \text{if } k \geq 0 \\ \mathsf{Vol}\{(M \ominus 2|k|B) \cap ((Z - \mathsf{Av}\{Z\}) \bullet |k|B)\} & \text{if } k < 0 \end{cases}$$

onde:

- $Z \circ kB$ é a abertura de Z por kB,
- $Z \bullet |k|B$ é o fechamento de Z por kB,
- N é o número de níveis de cinza na imagem (no nosso caso $N = 255$),
- **Vol**$\{\cdot\}$ é o volume da imagem, ou seja, $\mathbf{Vol}\{X\} = \sum_{w \in X} X(w)$,

- $\mathbf{Av}\{\cdot\}$ é a imagem média constante, ou seja, $\mathbf{Av}\{X\}$ é uma imagem de mesmo tamanho que X com altura constante igual a $\frac{1}{S} \cdot \mathsf{Vol}\{X\}$, onde S é o número de pixels de X,
- Z é a imagem de entrada,
- M é a imagem máscara,
- B é o elemento estruturante (quadrado; segmento horizontal ou vertical), e
- $M \cap Z$ é a restrição da imagem Z à mascara M.

A Figura A.2 fornece um exemplo de curvas de abertura e fechamento. O lado direito (valores positivos do eixo horizontal) é a curva de abertura enquanto que o lado esquerdo (valores negativos do eixo horizontal) é a curva de fechamento.

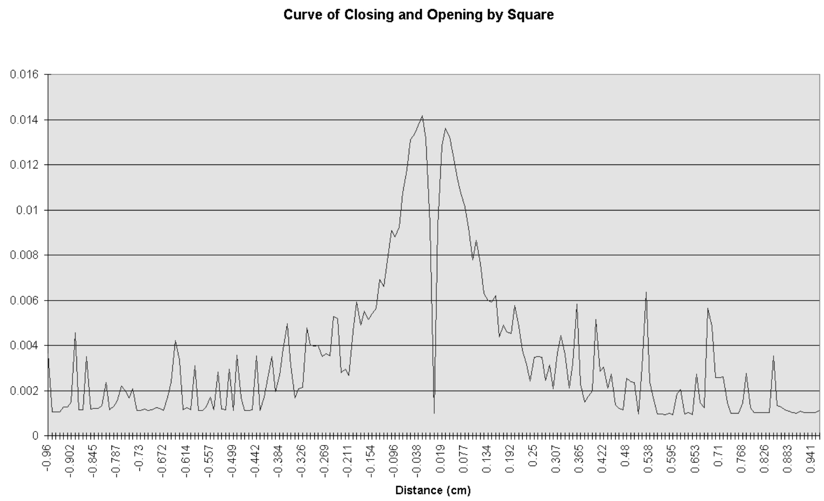

Figura A.2: Exemplo de uma curva de fechamento (lado esquerdo) e uma curva de abertura (lado direito) por elementos estruturantes quadrados.

A.3.2.3 Curva de Erosão e Dilatação

Nós também usamos uma "pseudo-granulometria" e "pseudo-antigranulometria" obtidas por uma substituição do fechamento e abertura por, respectivamente, dilatação e erosão [23]. Mais formalmente,

$$S(k) = \frac{1}{N} \cdot \frac{1}{\mathsf{Vol}\{M \ominus kB\}} \cdot \begin{cases} \mathsf{Vol}\{(M \ominus kB) \cap ((Z - \mathsf{Av}\{Z\}) \ominus kB)\} & \text{if } k \geq 0 \\ \mathsf{Vol}\{(M \ominus |k|B) \cap ((Z - \mathsf{Av}\{Z\}) \oplus kB)\} & \text{if } k < 0 \end{cases}$$

A velocidade da erosão é definida como a diferença $|S(k) - S(k+1)|$. Na Figura A.3 fornece um exemplo de uma curva de erosão e dilatação por segmentos verticais. Como no caso da granulometria, erosões e dilatações por quadrados (com tamanhos entre 1 a 100 pixels), segmentos horizontais e verticais (com tamanhos entre 1 a 100 pixels) foram usadas para a classificação de texturas.

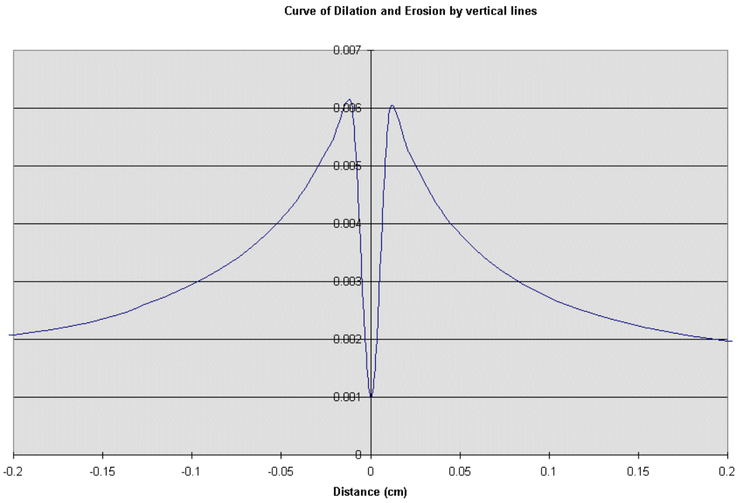

Figura A.3: Exemplo de uma curva de erosão (lado direito) e uma curva de dilatação (lado esquerdo) por segmentos verticais.

Observamos o cálculo das curvas de erosão e dilatação pode ser feito de uma maneira muito mais rápida que o cálculo das curvas de abertura e fechamento.

A.3.2.4 Medidas sobre Picos e Vales

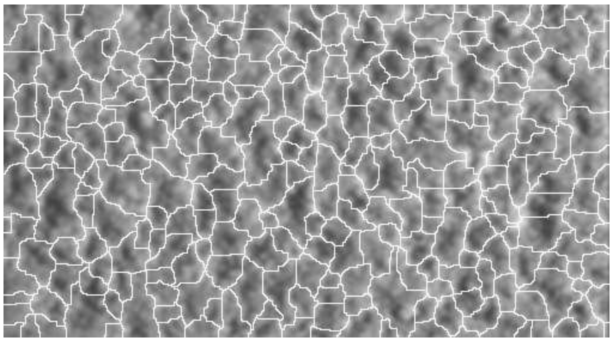

Figura A.4: Exemplo de "watersheds"

Para se obter informação sobre a conectividade dos picos e vales, extraímos os "watersheds" das imagens (um exemplo é dado na Figura A.4). A partir dessas imagens segmentadas, medimos o número de vales com uma dada área S, ou com um dado volume V (pela integração dos valores dos níveis de cinza para cada "watershed") e, analogamente, para o número de picos. Este tipo de informação está ilustrado na Figura A.5, onde a parte esquerda refere-se aos picos e a parte direita aos vales. Estes dados morfológicos foram usados em um estudo preliminar de superfícies, mas não foram relevantes para a classificação das texturas deste trabalho.

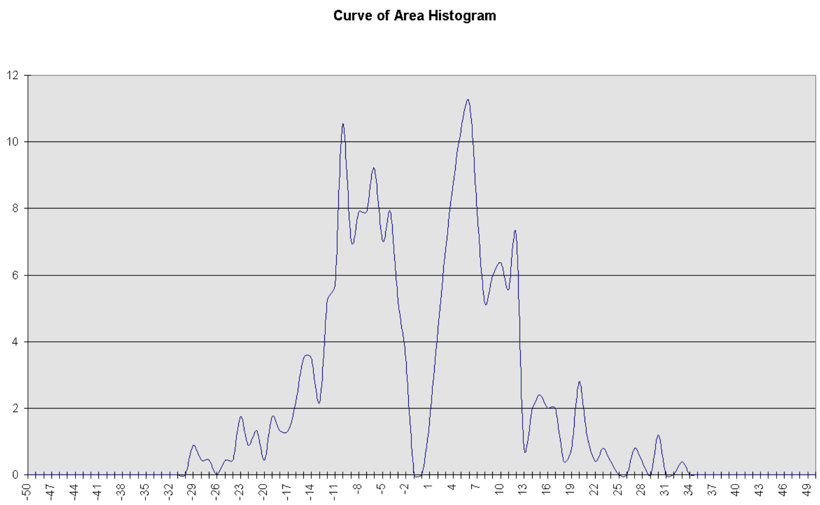

Figura A.5: Exemplo da distribuição de picos (parte esquerda) e de vales (parte direita)

A.4 Introdução à Análise de Correspondências

Para analisar as medidas morfológicas descritas na Seção A.3.2 e produzir uma classificação das amostras, usamos a *análise de correspondência* [13]. Um tratamento análogo foi feito em [26] para a classificação automática de inclusões não metálicas em rodas. Foi usado mais recentemente, para a classificação de superfícies rugosas [2], e para simulações de conjuntos aleatórios [3]. Os valores das medidas estão armazenados em uma tabela, onde toda linha corresponde a uma amostra (ou a uma *observação*) e toda coluna corresponde a uma medida (ou a uma *variável*). Definimos a *coordenada linha* de uma dada superfície (observação) como o vetor de M dimensões, e a *coordenada coluna* de uma dada medida (variável) como um vetor de N dimensões.

Técnicas alternativas de análise de fatores poderiam ser utilizadas para este propósito, como análise de fatores discriminantes, ou ainda análise de discriminantes penalizados [46]. Estas análises dividem com a análise de correspondência o fato de que uma combinação linear ótima das variáveis é procurada para a discriminação dos dados, e, na prática, estas análises fornecem resultados muito similares. Além disso, pode-se provar que a análise de correspondência é um caso especial da análise de fatores discriminantes, baseado sobre a métrica do “chi” quadrado [13].

A análise de correspondência permite construir um mapeamento das coordenadas linhas e colunas (pontos com M e N dimensões, respectivamente) em um espaço de dimensão reduzida (por exemplo, um espaço de dimensão dois) gerando critérios sintéticos (neste sentido, o método é um tipo de análise de fator [13]).

Nem todas as variáveis utilizadas na análise são importantes para separar as amostras. Esta análise permite encontrar as variáveis mais significativas entre as variáveis iniciais para a separação das amostras.

A análise de correspondência permite uma representação de nuvens de pontos linhas e colunas em um espaço reduzido, que separa na medida do possível todos pontos por uma maximização da inércia. Além disso, esta análise permite a interpretação dos eixos (ou fatores) do plano da representação em termos das variáveis iniciais. Isto é precisamente a principal vantagem deste método (com respeito à análise clássica de fatores).

Com uma indicação da qualidade dos eixos sintéticos é possível estimar a precisão da representação simplificada e a perda de informação, a partir da parte correspondente à inércia que cada eixo carrega. Por exemplo, se a primeira direção significa 45% de inércia, então ela sintetiza 45% da informação total. Obviamente, uma representação de pontos em um plano significa a soma de frações de inércia para cada eixo. Isto é importante para observar que podemos usar a "distância" entre imagens, bem como a "distância" entre as variáveis.

No exemplo do estudo mostrado na Figura A.6, observamos que a parte de inércia é 88.4% para o primeiro fator e 5.8% para o segundo. Isto significa que um vetor de 200 dimensões pode ser representado em um espaço de 2 dimensões mantendo o total de 95% de informação. A visualização dos pontos colunas permite identificar as medidas mais discriminantes. Para concluir esta parte, lembramos que a análise de correspondência permite:

- Visualizar as superfícies em um espaço reduzido (tipicamente 2 ou 3 dimensões) com a ajuda de fatores sintéticos.
- Dar uma interpretação para esta representação.
- Propor a redução do número de variáveis, útil para diminuir o tempo de medida para a etapa de classificação.

A.5 Resultados Experimentais

O estudo deste trabalho foi feito em três etapas. Na primeira, a importância dos elementos estruturantes direcionais são estimados (esta escolha é justificada pela iluminação direcional feita na aquisição das imagens das amostras). Em uma segunda etapa, as variáveis mais discriminantes são determinadas, a fim de reduzir o número de dados. Estas duas primeiras etapas foram feitas em uma base de dados reduzido (30 imagens de amostras). Na etapa final, estudamos a base de dados completa (300 imagens de amostras) sobre um número reduzido de medidas.

A.5.1 Primeira Etapa: Análise das Medidas

A primeira parte do estudo pretende avaliar se as texturas obtidas são realmente determinantes para caracterizar as diferentes qualidades do produto. As curvas de abertura e fechamento não forneceram bons resultados discriminantes, principalmente devido a fato que as curvas experimentais apresentaram muitas oscilações (veja a Figura A.2). Imagens maiores de cada amostra seriam requisitadas para proceder a análise estatística. Na parte restante do estudo, limitamos as medidas para as curvas de erosão e dilatação (e, assim, abandonando as medidas de abertura e fechamento). Elementos estruturantes direcionais aparentaram ser bons para a investigação desse estudo.

A.5.2 Segunda Etapa: Redução do Número de Variáveis

As projeções das variáveis no primeiro plano de fatores mostram a influência de cada variável sobre a discriminação. De fato, as variáveis mais dispersas nos planos de fatores são mantidas (duas variáveis próximas terão a mesma influência sobre a representação e classificação, e, portanto, uma só pode ser utilizada). Para a parte restante do estudo, é possível manter as seguintes medidas:

- A curva de covariança (horizontal e vertical), para distâncias entre 1 e 50 pixels.
- As curvas de erosão e dilatação, usando como elementos estruturantes segmentos horizontais e verticais com tamanho entre 1 e 30 pixels.
- As curvas de erosão e dilatação, usando elementos estruturantes quadrados com lados entre 1 e 50 pixels.

As medidas foram feitas para uma base de dados com 100 amostras de cada tipo de qualidade.

A.5.3 Estudo Final

Primeiramente, um resultado muito importante deste estudo é que a função de covariança não é suficientemente eficiente para discriminar as três categorias das amostras, enquanto que as operações morfológicas (erosão e dilatação) fornecem discriminação satisfatória das amostras. Usando uma simples regressão linear para definir os melhores limites para os diferentes domínios, obtemos, para estes exemplos, as pontuações dadas nas Figuras A.6 e A.7. Observamos que, no caso de operadores com elementos estruturantes com direção perpendicular à incidência da iluminação (Figura A.7), estes fornecem o melhor resultado (90% de pontuação da classificação). Isto é muito interessante, pois existem algoritmos muito rápidos para calcular erosões e dilatações direcionais. Como mostrado nas Figuras A.6 e A.7, algumas amostras não foram classificadas corretamente. A razãos para a classificação que não foi feita corretamente é que as texturas das amostras são muito similares às correspondentes amostras das outras famílias. Devemos observar que não é fácil separar as amostras por uma simples inspeção manual.

A.6 Conclusão

Apresentamos uma ferramente automática de classificação de texturas. Esta ferramente, usada aqui, é um estudo prático e baseado na análise de correspondência de dados morfológicos. Esta análise permite a visualização em um espaço sintético (aqui de duas dimensões), onde o significado de cada eixo é obtido pela projeção das variáveis neste mesmo espaço. A partir de observações das variáveis neste plano, as variáveis mais discriminantes podem ser extraídas. A classificação automática baseada nas curvas de erosão e dilatação (usando elementos estruturantes quadrados ou segmentos horizontais e verticais) fornecem resultados muito satisfatórios que a função de covariança neste estudo. Isto é consistente com a caracterização teórica de estruturas aleatórias pela capacidade de Choquet. Trabalhando-se com poucos dados otimizados (curvas de erosão e dilatação com elementos estruturantes de tamanho 30 ou 50), podemos obter uma boa classificação de texturas muito similares, com a pontuação de 90%. O controle de amostras mal classificadas mostra que elas são muito difícies de discriminar, mesmo para um observador experiente.

Este estudo é, de fato, em uma primera fase, uma aprendizagem para a classificação: usando a base de dados de referência, as melhores direções (ou fatores) que discriminam estas amostras são calculadas. Posteriormente, em uma segunda fase, para classificar uma nova amostra, temos que somente utilizar a projeção dela nestas direções calculadas no passo anterior (isto é, usa-se os resultados da etapa da aprendizagem, não é necessário recalcular novos fatores). Como resultado deste estudo, aparentemente erosões e dilatações lineares são bastante discriminantes para texturas muito similares, onde a covariança não funciona para separar tais amostras de superfícies.

A.7 Agradecimentos

Este estudo foi feito com a apoio financeiro da empresa “Weber & Broutin”, que forneceu as amostras de revestimento de parede. Este trabalho também teve o apoio financeiro do CNPq, proc. 200973/96-7.

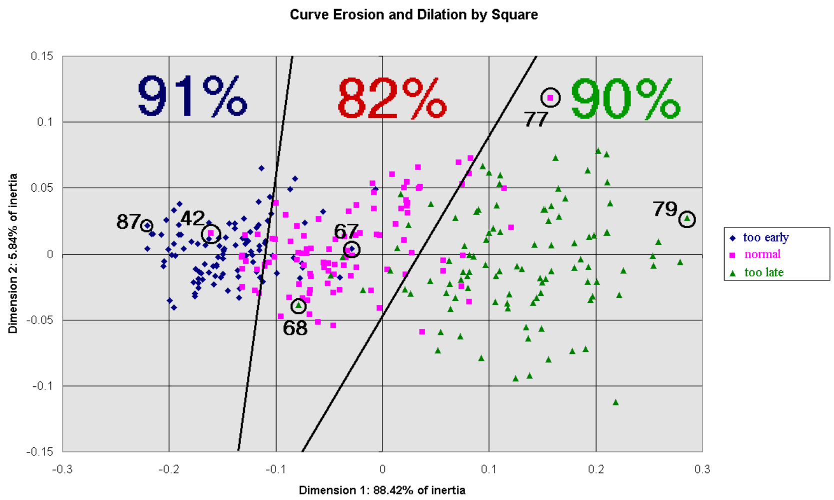

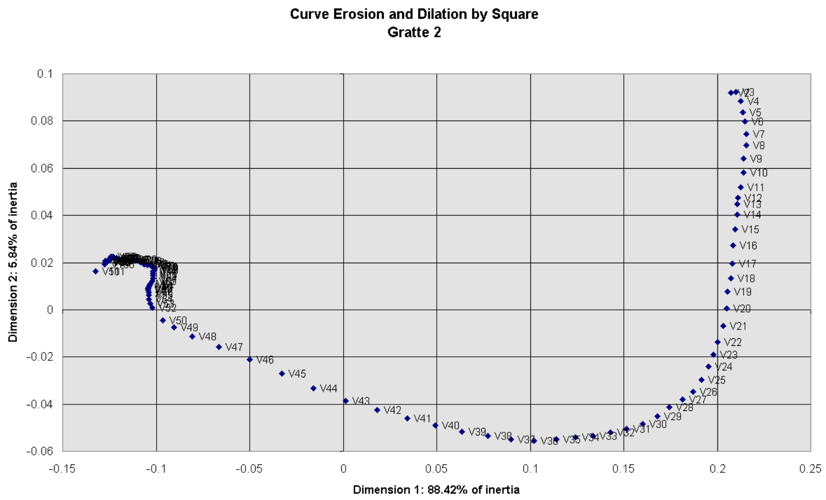

Figura A.6: Pontuação da classificação para as curvas de erosão e dilatação pelo quadrado e a correspondente representação das variáveis no primeiro plano de fatores.

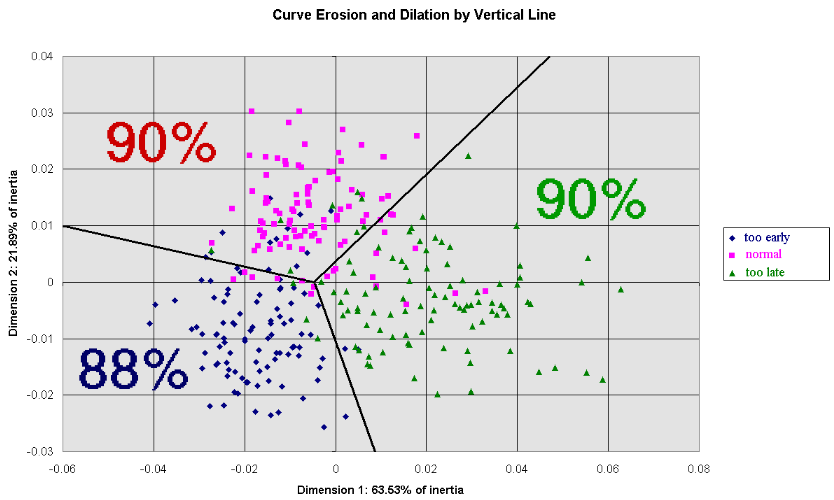

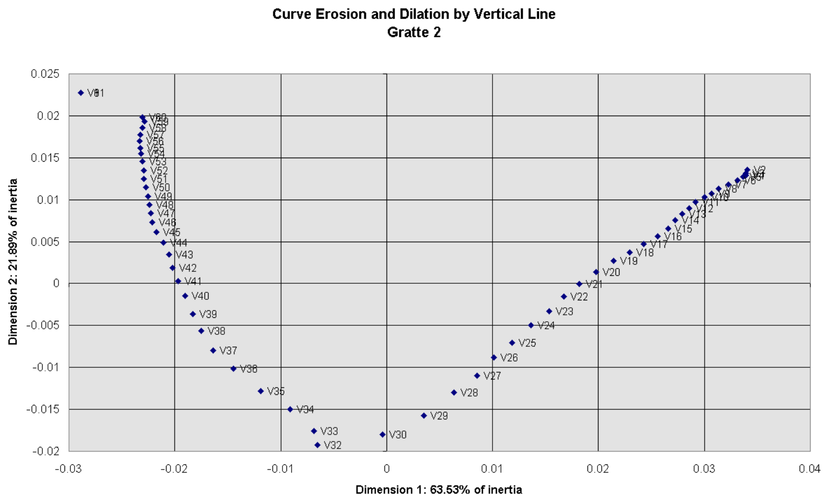

Figura A.7: Pontuação da classificação para as curvas de erosão e dilatação por linhas verticais e a correspondente representação das variáveis no primeiro plano de fatores.