



# TAS DAS I JORNADAS LUSÓFONAS DE CIÊNCIAS E TECNOLOGIAS DE INFORMAÇÃO GEOGRÁFICA

Editores

José Gomes dos Santos

Cidália Fonte

Rui Ferreira de Figueiredo

Alberto Cardoso

Gil Gonçalves

José Paulo Almeida

Sara Baptista



IMPRESA DA UNIVERSIDADE DE COIMBRA  
2015

## ARTIGO 40

### GENERALIZAÇÃO CARTOGRÁFICA DE LINHAS RECORRENDO A TÉCNICAS DE INTELIGÊNCIA ARTIFICIAL

*TRAVANCA LOPES, José<sup>1</sup> & CATALÃO, João<sup>2</sup>*

<sup>1</sup>Academia Militar; Av. Conde Castro Guimarães, 2720-113 Amadora; Email: jose.lopes@academiamilitar.pt

<sup>2</sup> Faculdade Ciências da Universidade de Lisboa; Instituto D. Luiz, Campo Grande, 1749-016 Lisboa; jcfernandes@fc.ul.pt

#### RESUMO

No processo de produção cartográfica a generalização cartográfica é considerada uma das tarefas mais complexas de automatizar pois depende de vários fatores independentes como a razão entre as escalas envolvidas, características geométricas da linha, contextualização e relações topológicas, entre outras. No caso particular de linhas, a sua generalização visa a remoção de detalhes desnecessários minimizando a degradação da sua função, identidade ou forma. Neste artigo propõe-se uma abordagem integrada de generalização de curvas de nível recorrendo a um algoritmo de generalização de linhas e técnicas de IA (Inteligência Artificial). A metodologia inclui a caracterização numérica das curvas de nível (dimensão fractal, angularidade, comprimento da linha, desvio padrão dos seus segmentos), o seu uso no treino de três algoritmos de inteligência artificial (rede neuronal, árvores de decisão e de classificação e regressão) com as quais se calcula o valor de um parâmetro a usar no algoritmo de generalização. Por fim é utilizado um agente, que executa um leilão e escolhe o 'melhor' entre os resultados preditos pelos métodos de IA. Esta metodologia foi aplicada na generalização da altimetria da série M888 escala 1/25.000 do IGeoE para a série M782

escala 1/50.000. Esta metodologia poderá ser análogamente utilizada noutros temas cartográficos e englobando outros algoritmos ou cadeias de algoritmos.

### **PALAVRAS-CHAVE**

Inteligência artificial, Generalização cartográfica, Redes neuronais, Árvores de decisão, Classificação de linhas.

## **1. INTRODUÇÃO**

No presente, a generalização cartográfica é realizada nas NMA (National Mapping Agency) de forma interativa semiautomática, englobando duas ou mais séries cartográficas e abrangendo diversas escalas. Com esta abordagem obtemos uma simbiose homem/máquina, para efectuar uma tarefa onde se alia o conhecimento processual e cartográfico do cartógrafo ao automatismo da máquina. Por este motivo, é necessário que o cartógrafo tenha muita experiência, em cartografia, seja um profundo conhecedor das regras cartográficas e no emprego dos algoritmos de generalização, antevendo possíveis resultados e problemas. Só detendo este nível de conhecimento e experiência se poderá obter bons níveis de execução e rentabilidade.

O grande desafio que se coloca à ciência é obter o conhecimento do cartógrafo, englobando as duas vertentes mencionadas e, de alguma forma passar para o computador a decisão de escolher que parâmetros e algoritmos utilizar na generalização de cada uma das entidades cartográficas. Pretende-se com este trabalho adquirir e utilizar, parte deste conhecimento, detido pelos cartógrafos e utilizá-lo na generalização de curvas de nível.

Alguns autores consideraram a generalização cartográfica como um problema de optimização. Foram desenvolvidas algumas abordagens de optimização para a generalização cartográfica, como o método das snakes (Bader e Barrault 2000), elastic beams (Bader e Barrault 2001) e ajustamento por mínimos quadrados (Sarjakoski e Kilpeläinen 1999). Neste grupo podemos incluir o projecto AGENT, proposto por Ruas e Plazanet (1996). A proposta baseia-se num modelo controlado por um conjunto de

constrangimentos. O objectivo do projecto AGENT assenta na modelação da natureza holística da generalização, recorrendo a tecnologia multi-agente (Ruas 2000). Em vez de usar um plano centralizado no processo da generalização, usa constrangimentos locais, regionais e globais, que são armazenados nos agentes. Estes agentes são os objectos cartográficos (micro-agentes), grupo de objectos (meso-agentes) ou as classes de objectos (macro-agentes) que podem comunicar e afectar outros agentes.

## 2. DADOS E MÉTODOS

Os dados iniciais são as curvas de nível da série M888 do IGeoE na escala 1:25000. A equidistância natural desta série é de 10 metros. O objetivo é a sua generalização para a escala 1:50000, cuja equidistância natural é de 20 metros. Por isso, e neste caso particular, foram seleccionadas para teste do algoritmo de generalização apenas as curvas de nível cujas cotas sejam múltiplas de 20m. Foram também seleccionados da BDG (Base de Dados Geográficos) os vértices geodésicos, alguns pontos de cota e todas as linhas de água, conforme esquematizado na Figura 1.

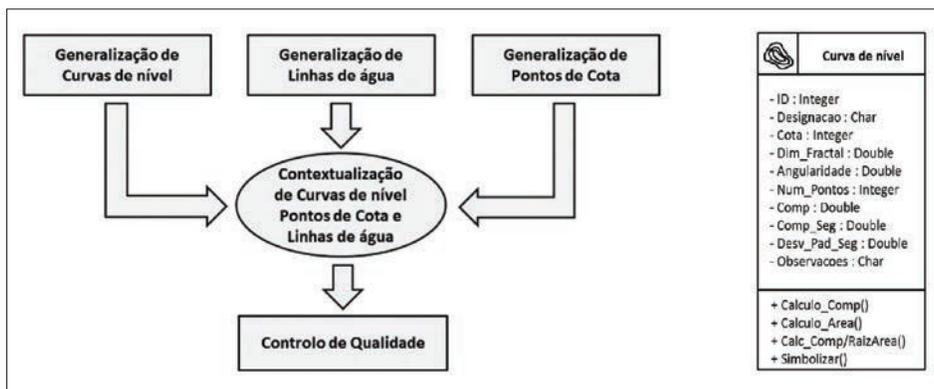


Figura 1 - Faseamento geral das actividades

Figura 2 - Atributos das Curvas de nível

Após a selecção das curvas de nível, é necessário efectuar a sua caracterização numérica, calculando a dimensão fractal, angularidade, média do comprimento dos segmentos, número de pontos etc. e adicionar estes

valores como atributos das linhas, ver Figura 2. Estes parâmetros são usados com entrada no processo de seleção do parâmetro ótimo para generalização das curvas de nível de acordo com o algoritmo de generalização de linhas proposto por Lopes (2006). Este algoritmo generaliza as curvas de nível com base num parâmetro de tensão a aplicar a cada linha. De acordo com este autor a tensão a aplicar é função dos parâmetros característicos da linha (previamente determinados). A tensão a aplicar a cada linha é determinado recorrendo a métodos de inteligência artificial, de acordo com as características geométricas específicas de cada curva de nível (Bernhardt 1992, Balboa 2008, Plazanet 1998). Por último efetua-se a contextualização, resolução de conflitos e avaliação dos resultados.

O projecto engloba uma Base de Dados do conhecimento que armazena as regras cartográficas utilizadas e as prioridades das entidades, para efeitos de generalização, conforme representado na Figura 3.

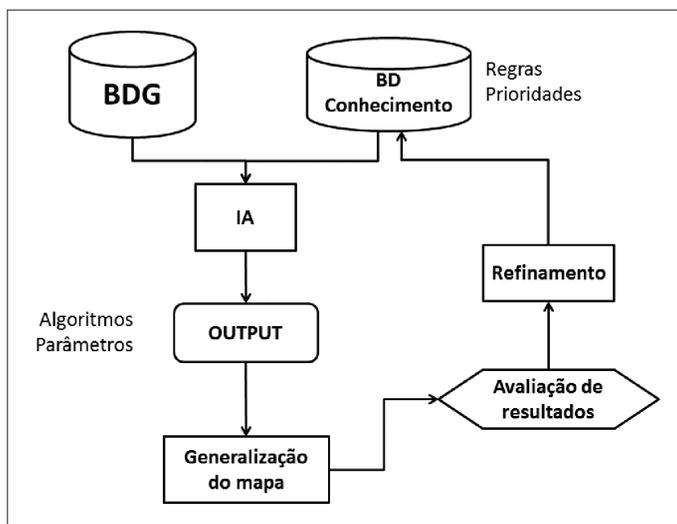


Figura 3 - Esquema geral da metodologia aplicada

### 3. GENERALIZAÇÃO DE CURVAS DE NÍVEL

#### 3.1. Uso da IA na generalização de curvas de nível

A generalização das curvas de nível é efectuada com o algoritmo proposto por Lopes (2006). Este algoritmo requer um valor para a tensão a

aplicar a cada curva de nível que depende das características geométricas da curva, conforme Figura 4. Pretende-se que o cálculo do valor da tensão a aplicar à linha seja efectuada de forma automática, sem intervenção do operador humano. O computador tomará decisões que eram restritas do cartógrafo, apresentando como resultado final a tensão a utilizar numa curva de nível específica, ver Figura 5. Usou-se uma Rede Neuronal, uma Árvore de Classificação e Regressão e uma Árvore de Decisão, recorrendo ao algoritmo C5, ver sobre este assunto Gama *et al.* (2012), Russel e Norvig (2003), Quinlan (1986) e Kohavi e Quinlan (1999). Para os algoritmos de IA, utilizaram-se os atributos da linha, como *input*, para obter o valor da tensão, como *output*.

Os outputs são depois comparados e analisados por um agente, num leilão, onde é escolhido o “melhor” valor para o parâmetro tensão, a utilizar na generalização das curvas de nível. Para treinar a rede neuronal e construir as árvores de decisão e classificação e regressão, utilizam-se dados representativos do conjunto que se pretende generalizar.

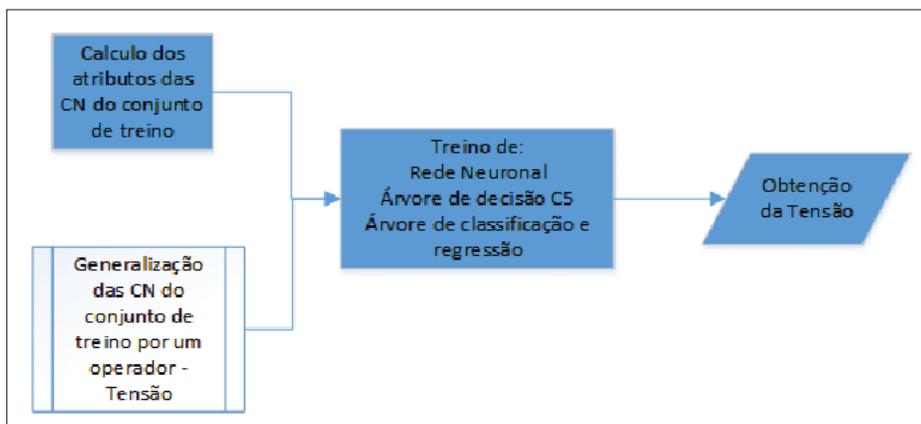


Figura 4 - Fases do treino

Após este treino e esta validação é possível tirar partido, da rede neuronal treinada para estes casos e, das árvores de decisão e de classificação e regressão de forma a generalizar as curvas de nível das restantes folhas da série M888, para serem representadas na série M782 à escala 1/50 000.

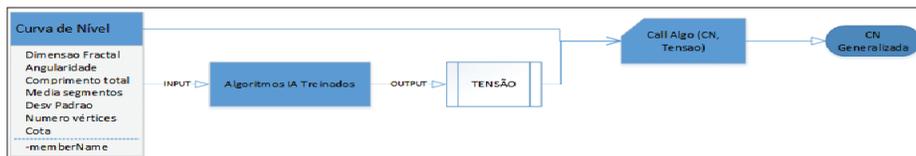


Figura 5 - Generalização das Curvas de Nível

O processo de aprendizagem, inclui a preparação de dados, definição de variáveis e respectivos domínios, incluindo aqui os atributos caracterizadores das curvas de nível e os valores da tensão seleccionados pelo cartógrafo, para cada linha de entrada, Figura 6a) e b). É também aqui definida a variável de saída, onde os valores da tensão para cada método de IA são armazenados.

Para os novos casos, os atributos caracterizadores das curvas de nível são conectados à rede neuronal, árvore de classificação e regressão e árvore de decisão que, com os parâmetros previamente refinados durante o processo de aprendizagem, produzem como saída um valor de tensão a utilizar no algoritmo de generalização, ver Figura 6 d1) d2) e d3), (*NN-Rede Neuronal, C&R-Árvore de Classificação e Regressão, C5-Árvore de Decisão recorrendo ao algoritmo C5*).

Utilizou-se uma Rede Neuronal multicamada. Foram testadas várias redes para discernir o número de camadas escondidas, após estas experiências concluiu-se que para este processo e com estes dados, os melhores resultados foram alcançados com 3 camadas intermédias escondidas. A camada de entrada integra 7 unidades, uma por cada atributo numérico caracterizador da curva de nível. Na camada de saída é apresentado o valor do parâmetro (tensão) a utilizar no algoritmo, ver Figura 6 f). Para função de activação utilizou-se uma sigmoide de 0.5.

Apesar das Redes Neurais serem ferramentas poderosas na resolução de problemas, é frequente integrar Redes Neurais com outros sistemas ou paradigmas, para obter soluções para problemas mais complexos, como por exemplo, na área da Robótica, veja (Russel e Norvig, 2003).

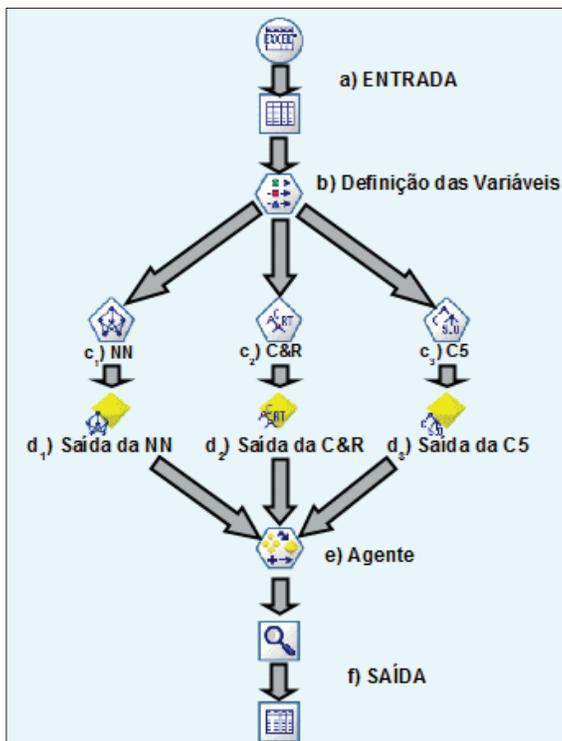


Figura 6 - Projecto Geral de actividades de Inteligência Artificial

Os resultados destes três métodos são combinados num nó, onde um agente realiza um “leilão”, de modo a que o valor de tensão calculado seja o “melhor” resultante dos três métodos. Este agente combina dois ou mais Outputs para obter predições, mais precisas que as dadas por cada método individualmente. Combinando predições de múltiplos métodos, as limitações destes métodos individuais podem ser corrigidas ou atenuadas, tendo como resultado final uma precisão superior, ver Figura 6e). A combinação destes métodos obtém um resultado, pelo menos tão bom como o melhor dos métodos individuais, sendo frequentemente melhor. É possível prever o valor da tensão a usar no algoritmo de generalização, ver Figura 6f), libertando o cartógrafo desta tarefa.

É necessário que a curva de nível generalizada seja avaliada por um cartógrafo. Pois sempre que se utiliza um algoritmo para generalizar, poderemos ter um resultado parcialmente aceitável.

### 3.2. Dados de teste

Efectuaram-se duas experiências com mapas da série M888 de escala 1/25 000 do IGeoE (*Instituto Geográfico do Exército*), com o objectivo de generalizar as curvas de nível destes mapas para a escala 1/50 000, os resultados foram posteriormente comparados com a generalização manual. Escolheu-se um conjunto de 249 curvas de nível pertencentes à folha N° 309 da série M888 para treinar a rede neuronal e construir as árvores de decisão e classificação e regressão. Após o treino é necessário um outro conjunto de dados para validação, para isso escolheu-se um conjunto de 292 curvas de nível da folha N°50.

As curvas de nível usadas no processo de aprendizagem englobam um grande conjunto de formas, como se pode ver na Tabela 1 a sua dimensão fractal varia desde 1.049 a 1.577, o que significa que a sua sinuosidade vai desde o quase plano até ao muito sinuoso, o número de vértices varia entre 10 e 11339 conjugado com o comprimento da linha, média do comprimento dos seus segmentos e respectivo desvio padrão é indicativo da sua complexidade, resultando num conjunto de linhas abrangente e demonstrativo.

Tabela 1 - Estatísticas da caracterização de linhas

Parâmetro	Min	Max	Mediana	Média
Dimensão Fractal	1.049	1.577	1.361	1.351
Número de vértices	10	11339	77	475
Comprimento da linha (m)	50.7	107383.5	700.8	4575.1
Angularidade (gra)	5.2	34.0	9.6	10.0
Média dos segmentos(m)	4.9	13.4	8.8	9.0
Desvio padrão dos segmentos (m)	4.1	698.1	48.1	86.9
Cota das curvas de nível (m)	100	500	240	265

### 3.3. Treino

O sistema necessita de ser treinado com dados reais. Para isso um operador experiente seleccionou a tensão óptima a ser aplicada para cada curva de nível, de modo a ser generalizada da escala 1/25 000 para a escala 1/50 000. Foram processados dois conjuntos de curvas de nível: o primeiro para treinar o algoritmo e o segundo para avaliar a qualidade do processo de generalização.

Tabela 2 - Importância das variáveis no processo de classificação

Variáveis	C&R	C5	Rede Neuronal
Dimensão Fractal	0.642	0.697	0.314
Média dos Segmentos	0.243	0.041	0.198
Angularidade	0.083	0.115	0.109
Cota	0.017	0.042	0.090
Comprimento da linha	0.008	0.000	0.117
Desvio padrão dos segmentos	0.008	0.093	0.069
Número de vértices	0.000	0.012	0.104

Analisando os dados da Tabela 2 podemos observar que para qualquer dos métodos, a dimensão fractal é aquela que apresenta a maior importância para a classificação, o número de vértices e o comprimento da linha não influenciam grandemente esta classificação.

Neste caso foi usado uma árvore de decisão (C5) com profundidade de 8, não foi aplicado nenhum método de poda extra, para além do utilizado pelo próprio algoritmo na construção da árvore, não houve nenhum tratamento ao nível dos suplentes, pois o número de casos não é excessivamente grande e todos os atributos estão preenchidos, não havendo atributos vazios ou nulos. As classes usadas para a aprendizagem supervisionada foram os valores da tensão possíveis, usados na generalização de curvas de nível.

### 3.4. Resultados

As três soluções usadas no processo foram analisadas pelo sistema a fim de seleccionar a tensão óptima a aplicar às linhas. Para validação do processo foram usadas 292 curvas de nível da folha N°50 cujas matrizes de confusão são apresentadas abaixo. A qualidade do resultado, foi testada por comparação da metodologia proposta e a generalização efectuada por um cartógrafo experiente, das curvas de nível da mesma carta. As colunas representam a tensão indicada pelo cartógrafo e as linhas correspondem à tensão estimada pelo algoritmo. Analisou-se separadamente a Rede Neuronal (Tabela 3), a árvore de decisão com o algoritmo C5 (Tabela 4), a árvore de classificação e regressão (Tabela 5) e após a utilização do agente (Tabela 6).

Tabela 3 - Matriz de confusão para a Rede Neuronal

**Operador/Rede Neuronal**

	0	1	2	3	4	5	6	7	8	9	10	Total
0												
1		13	53									66
2			61		1	1						63
3			5	2								7
4			10			1						11
5			15	1	2	120	3	1	1			143
6							2					2
7												
8												
9												
10												
Total		13	144	3	3	122	3	3	1			292

Pc - Percentagem de concordância 67%

Tabela 4 - Matriz de confusão para a Árvore C5

**Operador/Árvore de decisão C5**

	0	1	2	3	4	5	6	7	8	9	10	Total
0												
1			7									7
2		13	128	2	1	36						180
3												
4			2		1	19						22
5			7	1	1	54	2	1				66
6						3	1					4
7						10		2	1			13
8												
9												
10												
Total		13	144	3	3	122	3	3	1			292

Pc - Percentagem de concordância 63%

Tabela 5 - Matriz de confusão para a Árvore C&R

**Operador/Árvore C&R**

	0	1	2	3	4	5	6	7	8	9	10	Total
0												
1			7									7
2		13	129	2	1	36						180
3												
4			2		1	19						22
5			5	1	1	55	2	1				66
6						3	1					4
7						10		2	1			13
8												
9												
10												
Total		13	143	3	3	123	3	3	1	0		292

Pc - Percentagem de concordância 64%

Tabela 6 - Matriz de confusão depois do Agente

**Operador/Agente**

	0	1	2	3	4	5	6	7	8	9	10	Total
0												
1		5	1									6
2		8	126	2		15						151
3					1							1
4			6		2	4						12
5			11	1	1	102	3	1	1			120
6												
7								2				2
8												
9												
10												
Total		13	144	3	4	121	3	3	1			292

Pc - Percentagem de concordância 81%

Após o treino da Rede Neuronal e construção das árvores de decisão, foram comparados os valores preditos por estes métodos e os considerados por um operador experiente, para o conjunto de linhas de verificação (curvas de nível), na análise destas podemos verificar que as maiores tensões não são usadas, nem pelo operador nem pelos métodos de IA, pelo que para o rácio destas escalas a deformação das linhas não deve ser muito elevada. Com a utilização do agente obtemos um ganho considerável na predição do valor da tensão a usar, quando combinamos os três métodos.

## 4. RESULTADOS E VALIDAÇÃO

### 4.1. Validação quantitativa

Para a validação quantitativa, calcularam-se diversas medidas das curvas de nível e compararam-se entre si os valores das curvas homólogas. Utilizaram-se nesta comparação algumas medidas não utilizadas na caracterização numérica das linhas, como a área ocupada pela curva de nível, a diferença das áreas envolvidas e a área diferença, comparou-se ainda valor do comprimento sobre a raiz quadrada da área. Algumas curvas de nível são interrompidas nos limites da folha, nestes casos optou-se por considerar os limites da folha da série M888, formando a menor área, como pertencendo à curva. Os resultados da comparação entre os dados da série M888 escala 1/25000 e M782 escala 1/50000, são apresentados na Tabela 7, onde o valor das áreas é dado em metros quadrados.

Tabela 7 - Comparação entre as curvas de nível, originais 25k e generalizadas manualmente 50k, folha 279

CNível	Area_25k	Area_50k Manual	Dif_25_50k _Manual	Slivers_25_50k	Dif_Slivers- Dif_25_50k	$\frac{Comp\ 25k}{\sqrt{Area}}$	Comp_50k	$\frac{Comp\ 50k}{\sqrt{Area}}$
Min	3.09E+03	3.11E+03	-23384.15	38.36	-316579.58	2.61535	190.92	2.62543
Max	7.33E+07	7.33E+07	344271.68	124429.75	147813.89	32.08369	129593.46	31.68225
Media	2.56E+06	2.55E+06	1849.61	6137.39	4266.23	6.02446	7158.19	5.96835
Mediana	8.47E+04	8.68E+04	58.82	1244.44	1320.43	5.14928	1570.76	5.13889
DesvPad	8.72E+06	8.70E+06	21824.81	13936.17	25072.79	3.16316	15204.02	3.12171

Da tabela anterior podemos verificar que o valor da área ocupada diminui, da 25k para a 50k, aumentando nalguns casos, principalmente onde o comprimento das linhas é menor e se pretende que as mesmas tenham representatividade na escala menor. A área dos *slivers*, não apresenta um valor muito elevado, pelo que o afastamento das linhas não deve ser muito acentuado. Comparando os valores dados pelo  $\frac{Comp}{\sqrt{Area}}$ , podemos verificar que os valores são semelhantes, sendo inferiores para a série M782, exceptuando o seu mínimo que é ligeiramente superior, o que concorda com os dados apresentados anteriormente. Também o comprimento das linhas diminui com a generalização manual, da escala 25k para 50k.

Comparando as áreas ocupadas pelas curvas de nível, generalizadas

manualmente e automaticamente, podemos constatar que concordam entre si, nos seus valores máximos e na média, os valores mínimos apresentam uma pequena diferença não muito significativa, devido ao facto do algoritmo não efectuar exageros, diminuindo o valor dos comprimentos e das áreas. Verifica-se que a diferença entre os  $Comp/\sqrt{Área}$  manual e automática tem de média um valor próximo de 0.2, os valores máximo, mínimo e mediana também têm valores baixos na ordem dos 0.2, havendo concordância entre os valores dados para as curvas de nível generalizadas manualmente e automaticamente.

Tabela 8 - Comparação entre as curvas de nível, generalizadas manualmente e automaticamente 50k, folha 279

	Area_50K Manual	Comp_50k Manual	Comp/Raiz (Area_50k)	Area_GenAut	Comp_GenAut	$\frac{Comp\ 50k\ Gen}{\sqrt{Área}}$	DifArea50k Man_Aut	Dif Com 50k/raiz Man Aut	Silvers_50 kMan_50k Aut
Min	3.11E+03	190.92	2.63	2.88E+03	1.75E+02	2.62	-1.31E+06	-8.45	225.06
Max	7.33E+07	1.3E+05	31.68	7.34E+07	1.20E+05	29.70	8.35E+04	1.99	2.37E05
Media	2.55E+06	7.16E+03	5.97	2.55E+06	6.74E+03	5.70	-2.63E+03	0.24	1.75E+04
Mediana	8.68E+04	1.57E+03	5.14	8.18E+04	1.45E+03	4.99	1.54E+03	0.20	4.89E+03
Desvpad	8.70E+06	1.52E+04	3.12	8.71E+06	1.42E+04	2.90	8.57E+04	0.64	3.18E+04

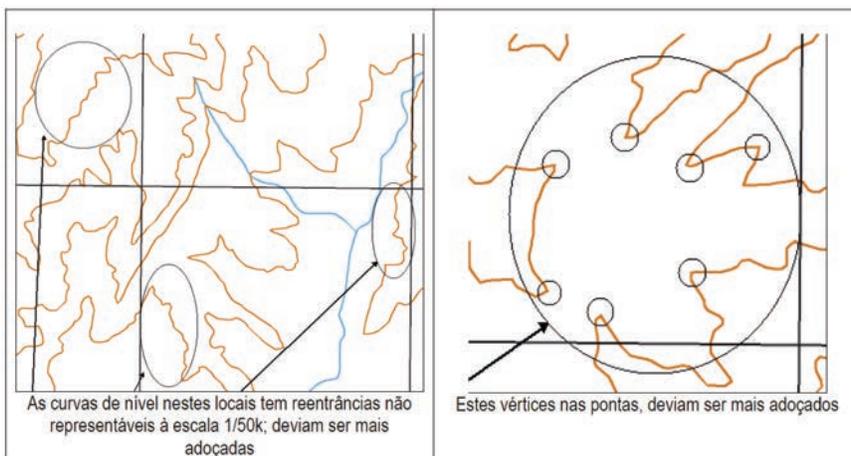


Figura 7 - Erros apontados pelos operadores da Secção de Controlo de Qualidade

#### 4.2. Validação qualitativa

Esta validação foi efectuada na Secção de Controlo de Qualidade do IGeoE, onde as folhas generalizadas, foram submetidas ao processo de

controlo de qualidade. A validação quantitativa é notoriamente incompleta para estes casos de cartografia, pois mesmo apresentando valores da tensão a utilizar, concordantes entre este método e os valores obtidos pelos operadores, é necessário verificar se as regras cartográficas não foram comprometidas, assim como a topologia e legibilidade do produto final. Apenas com uma visualização da representação dos dados por um operador cartógrafo, esta avaliação é possível, não podemos dispensar esta avaliação qualitativa sob o risco de obter um mapa não legível ou em condições de utilização muito insipientes.

## 5. CONCLUSÃO

Neste artigo apresentou-se uma metodologia de generalização de curvas de nível, utilizando um algoritmo cujo parâmetro é calculado recorrendo a técnicas de IA. Utilizou-se uma rede Neuronal, uma Árvore de decisão e uma Árvore de classificação e regressão para calcular o parâmetro tensão. O ‘melhor’ parâmetro é seleccionado através de um leilão efectuado por um Agente, onde os licitantes são os métodos de IA, utilizados na predição. O foco desta metodologia centra-se na deformação da curva de nível e sua contextualização com as outras entidades dos temas da altimetria e hidrografia. Pretende-se libertar o cartógrafo da escolha do parâmetro a utilizar, recorrendo a uma analogia com a deformação de um corpo bidimensional. Efectuou-se a classificação das linhas de água e consequente selecção para a escala 1/50.000. A validação quantitativa e qualitativa mostraram que o resultado desta metodologia efectivamente concorda com a generalização cartográfica manual e interactiva, havendo um ganho considerável em tempo de operador. A metodologia proposta poderá ser aplicada a outros temas da cartografia e outros algoritmos.

## BIBLIOGRAFIA

BADER, M.; Barrault M. (2000), “Improving Snakes for Linear *Feature* Displacement in Cartographic Generalization”, *Spatial Data Handling, Department of Geography, University of Zurich, Winterthurerstrasse 190, CH-8057 Zurich, Switzerland*;

- BADER, M.; Barrault M. (2001), "Cartographic Displacement in Generalization: Introducing Elastic Beams", Fourth Workshop on Progress in Automated Map Generalization, Beijing, China, August 2-4.
- BALBOA, J.; López, J.; Luque R. (2008) "Road line classification for cartographic generalization: a neural net approach", Grupo de Investigación en Ingeniería Cartográfica, Dpto. de Ingeniería Cartográfica, Geodésica y Fotogrametría, Universidad de Jaén. Campus, Las Lagunillas, s/n. 23071, Jaén (Spain).
- BERNHARDT, M. (1992), "Quantitative Characterization of Cartographic Lines for Generalization", Department of Geodetic Science and Surveying, The Ohio State University Columbus, Ohio 43210-1247.
- GAMA *et al.* (2012), "Extração de Conhecimento de Dados - Data Mining", Edições Sílabo, Lda, Lisboa, 2012. ISBN 978-972-618-698-4.
- KOHAVI, R. e Quinlan, J. (1999), Decision-tree discovery, in Will Klossen and Jan M. Zytkow, editors, Handbook of Data Mining and Knowledge Discovery, chapter 16.1.3, pages 267-276. Oxford University Press, 2002.
- LOPES, J. (2006), "Generalização Cartográfica", Tese de mestrado, Mestrado em Ciências e Engenharia da Terra, Faculdade de Ciências da Universidade de Lisboa.
- PLAZANET, C., Bigolin N., Ruas A. (1998), "Experiments with Learning Techniques for Spatial Model Enrichment and Line Generalization", GeoInformatica, p.315-333, EPFL - Swiss Federal Institute of Technology Lausanne, Database Laboratory, CH-1015, Lausanne, Switzerland.
- QUINLAN, J., (1986), "Induction of Decision Trees", Machine Learning 1: 81-106, © 1986 Kluwer Academic Publishers, Boston - Manufactured in The Netherlands, Print ISSN 0885-6125.
- RUAS, A., (2000), "Project AGENT: Overview and Results of a European R&D Project in Map Generalisation", ICA Workshop, Barcelona, Spain.
- RUAS, A. e Plazanet, C., (1996), "Strategies for Automated Generalization". Proceedings of the 7th Spatial Data Handling Symposium, Delft, the Netherlands, pp. 319-336.
- RUSSEL, S.; Norvig, P. (2003) "Artificial Intelligence, a modern approach", Second Edition, Pearson Education, Inc. Upper Saddle River, New Jersey 07458, ISBN 0-13-080302-2.
- SARJAKOSKI, T., e Kilpeläinen, T., (1999), "Holistic Cartographic Generalization by Least Squares Adjustment for Large Data Sets", Finnish Geodetic Institute, Department of Cartography and Geoinformatics, P.O. Box 15, FIN-02431 Masala, Finland

Série Documentos

Imprensa da Universidade de Coimbra

Coimbra University Press

2015

