

Referências Bibliográficas

- [1] ALLAHVIRANLOO, T.; HAJARI, T. **Numerical methods for approximation of fuzzy data.** Applied Mathematics and Computations, 169(1):16–33, 2005.
- [2] ANDERSON, T. W.; TAYLOR, J. B. **Strong consistency of least squares estimates in normal linear regressions.** The Annals of Statistics, 4(4):788–790, 1976.
- [3] BORDIGNON, A.; CASTRO, R.; LEWINER, T.; LOPES, H.; MURAD, A.; SANTOS, R. ; TAVARES, G. **Métodos baseados em núcleos e máquinas de suporte vetorial em aplicações de geofísica de petróleo.** In: 10TH INTERNATIONAL CONGRESS OF THE BRAZILIAN GEOPHYSICAL SOCIETY, 2007.
- [4] BORDIGNON, A.; CASTRO, R.; LEWINER, T.; LOPES, H. ; TAVARES, G. **Point set compression through BSP quantization.** In: SIBGRAPI, p. 229–236. IEEE, 2006.
- [5] BREIMAN, L.; FRIEDMAN, J. H.; OLSHEN, R. A. ; STONE, C. J. **Classification and Regression Trees.** Chapman & Hall, 1984.
- [6] CASELLA, G.; BERGER, R. L. **Statistical Inference.** Duxbury, 2002.
- [7] CASTRO, R.; BORDIGNON, A.; LOPES, H.; LEWINER, T. ; TAVARES, G. **Multi-attribute seismic cell reservoir/non-reservoir classification with kernel based methods.** In: 27TH GOCAD MEETING, 2007.
- [8] CHANG, C.-C.; LIN, C.-J. **LIBSVM: a library for support vector machines,** 2001. Programa disponível no endereço <http://www.csie.ntu.edu.tw/~cjlin/libsvm>.
- [9] CHAUDHURI, P.; HUANG, M.-C.; LOH, W.-Y. ; YAO, R. **Piecewise-polynomial regression trees.** Statistica Sinica, 4(1):143–167, 1994.

- [10] CRISTIANINI, N.; SHawe-Taylor, J. **An Introduction to Support Vector Machines and Other Kernel-based Learning Methods**. Cambridge University Press, 2000.
- [11] DA ROSA, J. C.; VEIGA, A. ; MEDEIROS, M. C. **Tree-structured smooth transition regression models**. Computational Statistics & Data Analysis, 52:2469–2488, 2008.
- [12] DE JONG, P. **Forecasting general insurance liabilities**. Department of Actuarial Studies Research Series - Division of Economic and Financial Studies, Macquarie University, 2004.
- [13] DORAY, L. G. **Umvue of the IBNR reserve in a lognormal linear regression model**. Insurance: Mathematics and Economics, 18(1):43–57, 1996.
- [14] EICKER, F. **Asymptotic normality and consistency of the least squares estimators for families of linear regressions**. The Annals of Mathematical Statistics, 34(2):447–456, 1963.
- [15] ENGLAND, P. D.; VERRALL, R. J. **Stochastic claims reserving in general insurance**. British Actuarial Journal, 8(3):443–518(76), 2002.
- [16] FAN, R.-E.; CHEN, P.-H. ; LIN, C.-J. **Working set selection using the second order information for training SVM**. Journal of Machine Learning Research, 6:1889–1918, 2005.
- [17] FRIEDMAN, J. H. **Multivariate adaptive regression splines**. The Annals of Statistics, 19(1):1–67, 1991.
- [18] GESMANN, M. **Mack-, Bootstrap and Munich-chain-ladder methods for insurance claims reserving**, 2009. R Package at <http://code.google.com/p/chainladder/>.
- [19] HASTIE, T.; TIBSHIRANI, R. **Generalized Additive Models**. Monographs on Statistics and Applied Probability 43. Chapman & Hall, 1990.
- [20] HASTIE, T.; TIBSHIRANI, R. ; FRIEDMAN, J. **The Elements of Statistical Learning**. Springer Series in Statistics. Springer, 2001.
- [21] HERBST, T. **An application of randomly truncated data models in reserving IBNR claims**. Insurance: Mathematics and Economics, 25(2):123–131, 1999.

- [22] HOEL, P. G.; PORT, S. C. ; STONE, C. J. **Introduction to Statistical Theory.** The Houghton-Mifflin series in statistics. Houghton Mifflin, Boston, 1971.
- [23] HU, C.; CARDENAS, A.; HOOGENDOORN, S. ; JR., P. S. **An interval polynomial interpolation problem and its lagrange solution.** Reliable Computing, 4(1):27–38, 1998.
- [24] KREINOVICH, V. **Soft Methods for Integrated Uncertainty Modelling**, volume 37/2006 de **Advances in Soft Computing**, capítulo Statistical Data Processing under Interval Uncertainty: Algorithms and Computational Complexity, p. 11–26. Springer Berlin, Heidelberg, 2006.
- [25] KUBRUSLY, J.; DIAS, M.; LOPES, H. ; LAGE, M. **A hybrid chain ladder and gaussian process regression method for IBNR estimation.** Contributed Paper at The Fourth Brazilian Conference On Statistical Modelling in Insurance and Finance, 2009.
- [26] KUBRUSLY, J.; LOPES, H. ; VEIGA, A. **A probabilistic IBNR estimator using policy data.** Abstracts of the 10th International conference on Insurance: Mathematics and Economics, 1:15–15, 2006.
- [27] KUBRUSLY, J.; LOPES, H. ; VEIGA, A. **Um método probabilístico para cálculo de reservas do tipo IBNR.** Revista Brasileira de Risco e Seguro, 4(7):17–46, 2008.
- [28] KUBRUSLY, J.; VEIGA, A. ; LOPES, H. **Yet another IBNR estimator.** Proceedings of the Second Brazilian Conference on Statistical Modelling in Insurance and Finance, 2005.
- [29] KUZMAN, H. **A support vector machine for AVO interpretation.** 2003 SEG Abstracts, p. 181–184, 2003.
- [30] LAGE, M.; BORDIGNON, A.; PETRONETTO, F.; VEIGA, A.; TAVARES, G.; LEWINER, T. ; LOPES, H. **Approximations by smooth transitions in binary space partitions.** In: SIBGRAPI, p. 230–236. IEEE, 2008.
- [31] LI, J. **Multiatributes pattern recognition for reservoir prediction.** Geophys. Innovation: CSEG National Convention, p. 205–208, 2005.
- [32] LI, J.; CASTAGNA, J. **Support vector machine (svm) pattern recognition to AVO classification.** Geophysical Research Letters, 31(L02609), 2004.

- [33] LI, Q.; GRIFFITHS, J. ; WARD, J. **Constructive implicit fitting.** Computer Aided Geometric Design, 23:17–44, 2006.
- [34] LI, Q.; TIAN, J. **Blending implicit shapes using fuzzy set operations.** WSEAS Transactions on Information Science and Applications, 5(7):1230–1240, 2008.
- [35] MACK, T. **Measuring the variability of chain ladder reserve estimates.** Proceedings of the Casualty Actuarial Society Spring Forum, p. 101–182, 1994.
- [36] MACK, T. **Which stochastic model is underlying the chain ladder method?** Insurance: Mathematics and Economics, 15(2-3):133–138, 1994.
- [37] MARKOV, S.; POPOVA, E.; SCHNEIDER, U. ; SCHULZE, J. **On linear interpolation under interval data.** Mathematics and Computers in Simulation, 42(1):35–45, 1996.
- [38] MOORE, R. E. **Interval Arithmetic and Automatic Error Analysis in Digital Computing.** Tese de Doutorado, Stanford University, October 1962.
- [39] MOORE, R. E. **Interval Analysis.** Prentice-Hall, 1966.
- [40] MOORE, R. E.; BIERBAUM, F. **Methods and Applications of Interval Analysis (SIAM Studies in Applied and Numerical Mathematics) (Siam Studies in Applied Mathematics, 2.** Soc for Industrial & Applied Math, 1979.
- [41] MULANSKY, B.; SCHMIDT, J. W. **Convex interval interpolation using a three-term staircase algorithm.** Numerische Mathematik, 82(2):313–337, 1999.
- [42] SHawe-Taylor, J.; Cristianini, N. **Kernel Methods for Pattern Analysis.** Cambridge University Press, 2004.
- [43] SMIRNOFF, A.; BOISVERT, E. ; PARADIS, S. J. **Support vector machine for 3d modelling from sparse geological information of various origins.** Computers & Geosciences, 34(2):127–143, 2008.
- [44] SMOLA, A. J.; SCHÖLKOPF, B. ; OLKOPF, B. S. **A tutorial on support vector regression.** Technical report, Statistics and Computing, 2003.

- [45] STOLFI, J.; DE FIGUEIREDO, L. H. **Self-Validated Numerical Methods and Applications.** Course in the 21st Brazilian Mathematics Colloquium, IMPA, 1997.
- [46] TARBELL, T. F. **Incurred but not reported claim reserves.** Proceedings of the Casualty Actuarial Society, Part II Volume XX, 1934.
- [47] VAPNIK, V. N. **The Nature of Statistical Learning Theory.** Statistics for Engineering and Information Science. Springer, 2ed edition, 2000.
- [48] WASSERMAN, L. **All of Nonparametric Statistics.** Springer Texts in Statistics. Springer, 2006.
- [49] ZHAO, B.; WEI ZHOU, H. **Nonlinear classification of AVO attributes using SVM.** AGU Joint Assembly - New Orleans, 2005.

A**Estimadores por Mínimos Quadrados para Regressões Lineares**

Sejam $Y = \{y_1, y_2, \dots, y_N\} \subset \mathbb{R}$ e $X = \{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_N\} \subset \mathbb{R}^n$ dados da amostra. Suponha que os dados se relacionam da seguinte forma:

$$y_i = \mathbf{f}(\mathbf{x}_i)\beta + \varepsilon_i, \quad \forall 1 \leq i \leq N \quad (\text{A-1})$$

onde $\mathbf{f} : \mathbb{R}^n \rightarrow \mathbb{R}^m$ é uma função conhecida, $\beta \in \mathbb{R}^m$ é o vetor de parâmetros da regressão e ε_i é uma variável aleatória normal de média nula e variância σ^2 , que representa o erro na estimativa.

Suponha $\mathbf{f}(\mathbf{x}) = (\mathbf{f}_1(\mathbf{x}), \dots, \mathbf{f}_m(\mathbf{x}))$. A equação A-1 pode ser escrita na seguinte forma matricial.

$$\underbrace{\begin{pmatrix} y_1 \\ y_2 \\ \vdots \\ y_N \end{pmatrix}}_y = \underbrace{\begin{pmatrix} \mathbf{f}_1(\mathbf{x}_1) & \mathbf{f}_2(\mathbf{x}_1) & \dots & \mathbf{f}_m(\mathbf{x}_1) \\ \mathbf{f}_1(\mathbf{x}_2) & \mathbf{f}_2(\mathbf{x}_2) & \dots & \mathbf{f}_m(\mathbf{x}_2) \\ \vdots & \vdots & & \vdots \\ \mathbf{f}_1(\mathbf{x}_N) & \mathbf{f}_2(\mathbf{x}_N) & \dots & \mathbf{f}_m(\mathbf{x}_N) \end{pmatrix}}_{\mathbf{M}} \underbrace{\begin{pmatrix} \beta_1 \\ \beta_2 \\ \vdots \\ \beta_m \end{pmatrix}}_\beta + \underbrace{\begin{pmatrix} \varepsilon_1 \\ \varepsilon_2 \\ \vdots \\ \varepsilon_N \end{pmatrix}}_\varepsilon \quad (\text{A-2})$$

O estimador por mínimos quadrados para β é aquele que minimiza a soma dos quadrados dos erros. Ou seja,

$$\hat{\beta} = \arg \min_{\beta \in \mathbb{R}^m} \sum_{i=1}^N (y_i - \mathbf{f}(\mathbf{x}_i)\beta)^2 = \arg \min_{\beta \in \mathbb{R}^m} \sum_{i=1}^N \left(y_i - \sum_{j=1}^m \mathbf{f}_j(\mathbf{x}_i)\beta_j \right)^2$$

Para encontrar $\hat{\beta}$ a equação acima será derivada e igualada a zero. Como resultado tem-se:

$$\frac{\partial}{\partial \beta_k} = 0 \Rightarrow \sum_{i=1}^N \sum_{j=1}^m \mathbf{f}_k(\mathbf{x}_i) \mathbf{f}_j(\mathbf{x}_i) \beta_j = \sum_{i=1}^N \mathbf{f}_k(\mathbf{x}_i) y_i$$

Considerando as derivadas em todas as variáveis, $\beta_1 \dots \beta_m$, o problema passa a ser um sistema $m \times m$ representado pela seguinte forma matricial:

$$\mathbf{M}^t \mathbf{M} \boldsymbol{\beta} = \mathbf{M}^t y \quad (\text{A-3})$$

onde a matriz \mathbf{M} e os vetores $\boldsymbol{\beta}$ e y estão definidos na equação A-2.

A.1

Condição para Existência

Para que exista $\hat{\boldsymbol{\beta}}$ que seja solução do sistema A-3 é suficiente que a matriz $\mathbf{M}^t \mathbf{M}$ seja inversível. Nesse caso:

$$\hat{\boldsymbol{\beta}} = (\mathbf{M}^t \mathbf{M})^{-1} \mathbf{M}^t y \quad (\text{A-4})$$

A.2

Estimador não Tendencioso

Definição A.2.1 Um estimador $\hat{\boldsymbol{\beta}}$ é chamado um estimador não tendencioso para o parâmetro $\boldsymbol{\beta}$ se $\mathbf{E}[\hat{\boldsymbol{\beta}}] = \boldsymbol{\beta}$.

A definição acima foi tirada do livro de Hoel, Port e Stone (22). Observe que $\mathbf{E}[\hat{\boldsymbol{\beta}}] = \boldsymbol{\beta}$ é o mesmo que $\mathbf{E}[\hat{\boldsymbol{\beta}} - \boldsymbol{\beta}] = 0$.

Proposição A.2.2 Supondo $\mathbf{M}^t \mathbf{M}$ não singular, é possível afirmar que o estimador $\hat{\boldsymbol{\beta}}$ definido pela equação A-4 é não tendencioso.

Demonstração:

$$\begin{aligned} \hat{\boldsymbol{\beta}} &= (\mathbf{M}^t \mathbf{M})^{-1} \mathbf{M}^t y \\ \hat{\boldsymbol{\beta}} &= (\mathbf{M}^t \mathbf{M})^{-1} \mathbf{M}^t (\mathbf{M}\boldsymbol{\beta} + \boldsymbol{\varepsilon}) \\ \hat{\boldsymbol{\beta}} &= (\mathbf{M}^t \mathbf{M})^{-1} \mathbf{M}^t \mathbf{M}\boldsymbol{\beta} + (\mathbf{M}^t \mathbf{M})^{-1} \mathbf{M}^t \boldsymbol{\varepsilon} \\ \hat{\boldsymbol{\beta}} &= \boldsymbol{\beta} + (\mathbf{M}^t \mathbf{M})^{-1} \mathbf{M}^t \boldsymbol{\varepsilon} \\ \hat{\boldsymbol{\beta}} - \boldsymbol{\beta} &= (\mathbf{M}^t \mathbf{M})^{-1} \mathbf{M}^t \boldsymbol{\varepsilon} \\ &\Downarrow \\ \mathbf{E} [\hat{\boldsymbol{\beta}} - \boldsymbol{\beta}] &= \mathbf{E} [(\mathbf{M}^t \mathbf{M})^{-1} \mathbf{M}^t \boldsymbol{\varepsilon}] = 0 \end{aligned}$$

□

A.3

Condição para Consistência

Observe que $\hat{\boldsymbol{\beta}}$ depende do tamanho da amostra, uma vez que \mathbf{M} e y dependem de N . Por isso, nessa seção, ele será chamado de $\hat{\boldsymbol{\beta}}_N$ e $\mathbf{M}^t \mathbf{M}$ será chamado de $\mathbf{M}^t \mathbf{M}_N$. Assim $\{\hat{\boldsymbol{\beta}}_N\}_{N=1}^\infty$ define uma sequência de estimadores.

A seguir, a definição de estimador consistente, retirada do livro do Casella e Berger (6).

Definição A.3.1 *Uma sequência de estimadores $\hat{\beta}_N$ é uma sequência consistente de estimadores para o parâmetro β se $\hat{\beta}_N$ converge em probabilidade para β . Isto é, se para todo $\epsilon > 0$, $\lim_{N \rightarrow \infty} P(|\hat{\beta}_N - \beta| < \epsilon) = 1$.*

Já foi mostrado, por Anderson e Taylor em (2) e por Eicker em (14), que a condição necessária e suficiente para $\hat{\beta}_N$ ser um estimador consistente para β é que $\lambda_{\min}(\mathbf{M}^t \mathbf{M}_N) \xrightarrow[N \rightarrow \infty]{} \infty$, onde $\lambda_{\min}(\mathbf{M}^t \mathbf{M}_N)$ é o menor autovalor da matriz $\mathbf{M}^t \mathbf{M}_N$.

B**SVR - Support Vector Regression**

Suponha o problema de aprender a relação entre certos pontos $\mathbf{x}_i \in \mathbb{R}^d$ e $y_i \in \mathbb{R}$ a partir de uma amostra de tamanho N definida pelo conjunto $\mathcal{S} = \{(\mathbf{x}_1, y_1), (\mathbf{x}_2, y_2), \dots, (\mathbf{x}_N, y_N)\}$. Uma das maneiras de resolver esse problema é através da ferramente de aprendisagem computaciobnal SVR.

A idéia principal por trás do SVR consiste em mapear $\mathbf{x} \in \mathbb{R}^d$ em um espaço de dimensão maior que d , chamado de \mathcal{F} , através de uma função não linear $\phi : \mathbb{R}^d \rightarrow \mathcal{F}$. Depois disso, com os dados já mapeados, é feita uma regressão linear nos dados $\{(\phi(\mathbf{x}_1), y_1), (\phi(\mathbf{x}_2), y_2), \dots, (\phi(\mathbf{x}_N), y_N)\}$. A função de previsão dessa regressão linear pode ser modelada por

$$f(\mathbf{x}) = \langle \mathbf{w}, \phi(\mathbf{x}) \rangle + b \quad (\text{B-1})$$

onde $b \in \mathbb{R}$ e $\mathbf{w} \in \mathcal{F}$. Observe que encontrar os valores de b e \mathbf{w} é um problema de regressão linear em \mathcal{F} , mas não em \mathbb{R}^d , por causa da função ϕ .

B.1**Problema Primal**

Para determinar os valores de b e \mathbf{w} será resolvido um problema de otimização quadrática, que busca minimizar a soma dos erros que ultrapassarem um certo valor. Esse problema é definido por:

$$\begin{aligned} & \text{Minimize}_{\mathbf{w}, b, \xi_i, \hat{\xi}_i} \quad \frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{i=1}^N (\xi_i + \hat{\xi}_i) \\ & \text{sujeito a:} \\ & \quad (\langle \mathbf{w}, \phi(\mathbf{x}_i) \rangle + b) - y_i \leq \varepsilon + \xi_i \quad i = 1, \dots, N \\ & \quad y_i - (\langle \mathbf{w}, \phi(\mathbf{x}_i) \rangle + b) \leq \varepsilon + \hat{\xi}_i \quad i = 1, \dots, N \\ & \quad \xi_i, \hat{\xi}_i \geq 0 \quad i = 1, \dots, N \end{aligned} \quad (\text{B-2})$$

onde as constantes C e ε são definidas pelo usuário e C representa a penalidade realizada quando o erro em um ponto qualquer for maior ε , que indica o erro máximo permitido sem penalidade. Já ξ_i e $\hat{\xi}_i$ são variáveis *slack*, que indicam o quanto o erro no ponto i ultrapassou ε .

B.2

Problema Dual

A forma dual do problema de otimização definido na equação (B-2) pode ser definida por:

$$\begin{aligned} \text{Maximize}_{\alpha_i, \hat{\alpha}_i} \quad & \sum_{i=1}^N (\hat{\alpha}_i - \alpha_i) y_i - \varepsilon \sum_{i=1}^N (\hat{\alpha}_i + \alpha_i) - \\ & \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N (\hat{\alpha}_i - \alpha_i)(\hat{\alpha}_j - \alpha_j) \langle \phi(\mathbf{x}_i), \phi(\mathbf{x}_j) \rangle \\ \text{sujeito a:} \quad & \sum_{i=1}^N (\hat{\alpha}_i - \alpha_i) = 0 \quad i = 1, \dots, N \\ & 0 \leq \alpha_i, \hat{\alpha}_i \leq C \quad i = 1, \dots, N \end{aligned} \quad (\text{B-3})$$

onde α_i e $\hat{\alpha}_i$ são os multiplicadores de Lagrange. As condições de Karush-Kuhn-Tucker (KKT) para esse problema são:

$$\begin{aligned} \alpha_i (\langle \mathbf{w}, \phi(\mathbf{x}_i) \rangle + b - y_i - \varepsilon - \xi_i) &= 0 \quad i = 1, \dots, N \\ \hat{\alpha}_i (y_i - \langle \mathbf{w}, \phi(\mathbf{x}_i) \rangle - b - \varepsilon - \hat{\xi}_i) &= 0 \quad i = 1, \dots, N \\ \hat{\alpha}_i \alpha_i = 0, \hat{\xi}_i \xi_i = 0 & \quad i = 1, \dots, N \\ (\hat{\alpha}_i - C) \hat{\xi}_i = 0, (\alpha_i - C) \xi_i = 0 & \quad i = 1, \dots, N \end{aligned}$$

B.3

Núcleo

Na forma dual, exposto na equação (B-3), o problema passa a depender apenas de $\langle \phi(\mathbf{x}_i), \phi(\mathbf{x}_j) \rangle$ e não mais de ϕ propriamente dito. De fato, para resolver esse problema, a função ϕ não será conhecida. O que se conhece é $K(\mathbf{x}_i, \mathbf{x}_j) = \langle \phi(\mathbf{x}_i), \phi(\mathbf{x}_j) \rangle$, que será chamada de função núcleo, ou simplesmente núcleo.

O núcleo é mais um parâmetro escolhido pelo usuário. Existem diversas alternativas, como por exemplo, o núcleo gaussiano definido por

$$K(\mathbf{x}_i, \mathbf{x}_j) = \exp \left(-\frac{\|\mathbf{x}_i - \mathbf{x}_j\|}{2\gamma^2} \right).$$

Para conhecer mais sobre os núcleos, sua definição e propriedades, uma boa referência é o livro de Shawe-Taylor e Cristianini (42).

B.4

Solução

Voltando ao problema dual definido na equação (B-3), se $(\hat{\alpha}_i - \alpha_i)$ for substituído por δ_i , utilizando as condições de KKT o problema pode ser reescrito para:

$$\begin{aligned}
 & \text{Maximize}_{\delta_1, \dots, \delta_l} \quad \sum_{i=1}^l \delta_i y_i - \varepsilon \sum_{i=1}^l |\delta_i| - \frac{1}{2} \sum_{i=1}^l \sum_{j=1}^l \delta_i \delta_j K(\mathbf{x}_i, \mathbf{x}_j) \\
 & \text{sujeito a:} \\
 & \quad \sum_{i=1}^l \delta_i = 0 \quad i = 1, \dots, l \\
 & \quad 0 \leq \delta_i \leq C \quad i = 1, \dots, l
 \end{aligned} \tag{B-4}$$

Seja $\delta^* = (\delta_1^*, \delta_2^*, \dots, \delta_N^*)$ a solução do problema exposto na equação (B-4), que pode ser obtida através de qualquer método em otimização quadrática, como por exemplo, para o caso do algoritmo LIBSVM (8) foi usado o SMO (*sequential minimal optimization*). A função de previsão definida pela equação (B-1) será:

$$f(\mathbf{x}) = \sum_{i=1}^N \delta_i^* K(\mathbf{x}_i, \mathbf{x}) + b^*,$$

onde $b^* = y_k - \varepsilon + \sum_{i=1}^N \delta_i^* K(\mathbf{x}_i, \mathbf{x}_k)$ para qualquer \mathbf{x}_k tal que $0 < \delta_k^* < C$. Para mais detalhes sobre o modelo e o algoritmo do SVR veja (10) e (44).

C

Aritmética Intervalar

A aritmética intervalar é uma extensão da aritmética para segmentos da reta. Um dos primeiros pesquisadores que desenvolveram essa teoria foi Moore, começando por sua tese de doutorado (38) e seguindo por diversas outras publicações, como por exemplo (39) e (40). A partir daí surgiram diversos artigos e livros sobre aritmética intervalar e o assunto virou foco de muita pesquisa, principalmente na área de computação numérica.

C.1 Intervalos

Um intervalo compacto real, ou somente um intervalo, é um subconjunto não-vazio, fechado e limitado de números reais da forma

$$[x] \equiv [\underline{x}, \bar{x}] := \{x \in \mathbb{R} \mid \underline{x} \leq x \leq \bar{x}\},$$

onde \underline{x} , é o limite inferior e \bar{x} é o limite superior do intervalo.

Os limites inferior e superior também são chamados, respectivamente, de *ínfimo* e *supremo*, e podem ser denotados por $\inf[x]$ e $\sup[x]$. O conjunto de todos os intervalos reais será chamado por \mathbb{IR} .

Um intervalo é chamado *pontual* se $\underline{x} = \bar{x}$, nesse caso pode-se escrever simplesmente x . O *interior* de um intervalo $[x]$, denotado por $]x[$ ou $\text{int}[x]$, é definido por:

$$]x[\equiv \text{int}[x] := \{x \in \mathbb{R} \mid \underline{x} < x < \bar{x}\}.$$

As relações de *igualdade* ($=$), *pertinência* (\in), *inclusão* (\subseteq), *inclusão própria* (\subset), *união* (\cap) e *interseção* (\cap) são extensões da teoria dos conjuntos.

A ordenação no conjunto \mathbb{IR} pode ser feita a partir da ordenação dos números reais da seguinte forma:

$$\begin{aligned} [x] < [y] &\Leftrightarrow x < y \text{ para todo } x \in [x] \text{ e } y \in [y] \\ [x] \leq [y] &\Leftrightarrow x \leq y \text{ para todo } x \in [x] \text{ e } y \in [y] \end{aligned}$$

C.2

Operações Elementares

As operações de soma, subtração, multiplicação e divisão são definidas em \mathbb{IR} da seguinte maneira:

$$\begin{aligned}\circ : \mathbb{IR} \times \mathbb{IR} &\rightarrow \mathbb{IR} \\ ([x], [y]) &\mapsto [x] \circ [y] = \{x \circ y \mid x \in [x] \text{ e } y \in [y]\}\end{aligned}$$

onde $\circ \in \{+, -, \cdot, /\}$ representa qualquer uma das quatro operações elementares. Dessa forma, a definição de $[x]/[y]$ é restrita a intervalos com $0 \notin [y]$. Fórmulas mais diretas podem ser usadas:

$$\begin{aligned}[x] + [y] &= [\underline{x} + \underline{y}, \bar{x} + \bar{y}] \\ [x] - [y] &= [\underline{x} - \bar{y}, \bar{x} - \underline{y}] \\ [x] \cdot [y] &= [\min\{\underline{x}\underline{y}, \underline{x}\bar{y}, \bar{x}\underline{y}, \bar{x}\bar{y}\}, \max\{\underline{x}\underline{y}, \underline{x}\bar{y}, \bar{x}\underline{y}, \bar{x}\bar{y}\}] \\ [x]/[y] &= [x] \cdot [1/\bar{y}, 1/\underline{y}], \text{ para } 0 \notin [y].\end{aligned}$$

É interessante observar que essas operações elementares obedecem a relação de *inclusão isotônica*:

$$[x] \subseteq [x'], [y] \subseteq [y'] \Rightarrow [x] \circ [y] \subseteq [x'] \circ [y'], \quad \forall \circ \in \{+, -, \cdot, /\}.$$

Somente algumas propriedades algébricas da aritmética de números reais permanecem válidas na aritmética intervalar. É possível ver, pela definição, que as operações de adição e multiplicação em \mathbb{IR} satisfazem as leis de comutatividade e associatividade. Os elementos neutros da adição e da multiplicação são, respectivamente, os intervalos $[0, 0]$ e $[1, 1]$.

Um propriedade que geralmente não é satisfeita é a lei da distributividade. Porém, uma forma mais fraca, chamada a lei de *subdistributividade*, pode ser aplicada em \mathbb{IR} :

$$\begin{aligned}[x] \cdot ([y] \pm [z]) &\subseteq [x] \cdot [y] \pm [x] \cdot [z], \\ ([y] \pm [z]).[x] &\subseteq [y].[x] \pm [z].[x].\end{aligned}$$

C.3

Funções Intervalares

Um dos grandes problemas da análise intervalar é avaliar a imagem de uma função real em um intervalo. Isto é, dada uma função real φ ,

$$\varphi : D \subset \mathbb{R} \rightarrow \mathbb{R},$$

e um intervalo $[x] \in D$, deseja-se encontrar $\varphi([x])$ definida por:

$$\varphi([x]) := \{\varphi(x) \mid x \in [x]\}.$$

Se φ for uma função contínua, então $\varphi([x])$ será um intervalo. Assim a função φ pode ser estendida para o conjunto \mathbb{IR} da seguinte forma:

$$\begin{aligned}\tilde{\varphi} : \quad \tilde{D} \subset \mathbb{IR} &\rightarrow \mathbb{IR} \\ [x] &\mapsto \tilde{\varphi}([x]) = \varphi([x])\end{aligned}$$

onde \tilde{D} representa todos os intervalos em D .

Usando propriedades de monotonicidade das funções reais elementares, pode-se escrever a imagem de algumas funções estendidas para intervalos, como por exemplo:

$$\begin{aligned}\varphi([\underline{x}, \bar{x}]) &= [\varphi(\underline{x}), \varphi(\bar{x})], \quad \text{se } \varphi \text{ é não decrescente} \\ \varphi([\underline{x}, \bar{x}]) &= [\varphi(\bar{x}), \varphi(\underline{x})], \quad \text{se } \varphi \text{ é não crescente} \\ \text{abs}([x]) &= [\langle [x] \rangle, |[x]|] \\ [x]^2 &= [\langle [x] \rangle^2, |[x]|^2]\end{aligned}$$

onde $\langle [x] \rangle$ representa o menor valor absoluto no intervalo $[x]$ e $|[x]|$ o maior valor absoluto.

Mas nem sempre é possível se encontrar uma expressão que defina a imagem de uma função real em um intervalo. Por isso um dos problemas fundamentais da aritmética intervalar é determinar, através de cálculos numéricos, um intervalo fechado que contenha essa imagem e que seja o mais próximo possível dela.

É fácil obter uma estimativa de $f([x])$ simplesmente substituindo x por $[x]$ na expressão que define f , e então avaliar f usando a aritmética intervalar. Assumindo que todas as operações de aritmética intervalar são bem definidas, este tipo de avaliação é chamada de *extensão natural* de f e é denotada por $f_{[]}([x])$.

Teorema C.1 (Teorema Fundamental da Aritmética Intervalar)

Sejam $f : D \subset \mathbb{R} \rightarrow \mathbb{R}$ uma função contínua, $f_{[]}$ a sua extensão natural e $[x] \in D$ um intervalo qualquer. Então, $f([x]) \subseteq f_{[]}([x])$.

A igualdade ocorre em situações muitas raras. Mesmo assim, muitas vezes, a extensão natural é o melhor que se pode fazer para estimar $f([x])$. Um estudo mais completo sobre aritmética intervalar pode ser encontrado no livro de Stolfi e Figueiredo (45).