



MS777 - Projeto Supervisionado 1

DETECÇÃO DE COMPRESSÃO COM A NORMA 1

ALUNO: MATHEUS QUEIROZ ZABIN

ORIENTADOR: PROF. DR. LÚCIO TUNES DOS SANTOS

Campinas, novembro de 2016

Sumário

1	Resumo	2
2	Introdução ao problema	2
3	Unicidade da solução	3
3.1	Análise inicial	3
3.2	Propriedade Isométrica Restrita	4
3.3	Propriedade Isométrica Restrita em matrizes aleatórias normais	5
4	Encontrando a solução esparsa de $Ax = b$ com a norma-1	5
5	Considerações finais	5
6	Referências Bibliográficas	6

1 Resumo

No mundo atual, o fluxo de dados (sinais, imagens, etc), está crescendo cada dia mais e de forma cada vez mais rápida. Porém, o número de características realmente significativas em uma quantidade relativamente grande de dados é, de forma geral, muito menor do que o número de coeficientes em uma representação de dados, ou seja, os dados são compressíveis. Em processamento de dados, o padrão é medir os dados brutos, e em seguida, comprimir estas medidas antes do armazenamento. Este processo de aquisição de dados pode ser nomeado como “detecção completa mais compressão”.

A técnica nomeada “Detecção de Compressão” (Compressive Sensing - CS), é uma metodologia cada vez mais utilizada no âmbito de processamento digitais de sinais, atraindo cada vez mais o olhar dos pesquisadores da área. O objetivo é reduzir o número de medições durante a fase de aquisição, de modo que nenhuma compressão adicional seja necessária. A teoria básica de CS, se fundamenta no fato de que um sinal qualquer de comprimento N , pode ser recuperado a partir de um número muito menor que N medições, através de otimização. O preço a ser pago é a necessidade de procedimentos de recuperação mais sofisticados.

2 Introdução ao problema

Nesta primeira etapa do trabalho será estudada a abordagem teórica do problema, para a posteriori realizar implementações numéricas dos conceitos estudados.

Considere um sinal discreto como um vetor $x \in \mathbb{R}^n$ e seja $b \in \mathbb{R}^m$ um vetor de medições tal que $b = Ax$, onde $A \in \mathbb{R}^{m \times n}$. O processo de obtenção de x a partir de um sinal desconhecido b é denominado codificação e o processo de recuperação de x a partir do vetor de medição b é denominado decodificação.

No problema

$$Ax = b, \quad (1)$$

existem situações onde $m = n$ e neste caso para realizar o processo de decodificação, basta resolver o sistema linear.

Porém, em muitas aplicações $m \ll n$ e com isso o problema (1) será um sistema possível indeterminado, i.e., existirão infinitas soluções para (1) e não seria possível realizar a recuperação do sinal. Nestes casos, para realizar a recuperação de x de forma eficaz, é razoável adicionar restrições ao problema (1) de forma a garantir a unicidade da solução.

Em geral, em situações práticas, b é obtida a partir de um sinal altamente esparso, ou seja, grande parte das componentes de x são nulas, e essa informação pode ser suficiente para se definir a restrição almejada.

Definindo $\|x\|_0$ como o número de elementos não nulos do vetor x , o problema (1) pode ser reformulado para a seguinte forma,

$$\min_x \{\|x\|_0 \mid Ax = b\}, \quad (2)$$

ou seja, o sinal que será recuperado deverá satisfazer $Ax = b$ e ao mesmo tempo ser o mais esparso possível. Porém, encontrar a solução com maior número de componentes nulas é computacionalmente intratável para sistemas muito grandes, e portanto uma alternativa mostra-se necessária.

A alternativa que será utilizada para tornar o problema computacionalmente viável será minimizar a norma- ℓ_1 de x em vez de minimizar $\|x\|_0$. Com isso, podemos formalizar um novo modelo,

$$\min_x \{\|x\|_1 \mid Ax = b\}, \quad (3)$$

que pode ser tratado computacionalmente como um problema de programação linear.

A escolha levanta algumas questões, como: Por que a norma- ℓ_1 recupera soluções esparsas? Sob quais condições a unicidade dessa solução é garantida?

Essas questões serão respondidas nas próximas seções, assim como a escolha da norma- ℓ_1 justificada.

3 Unicidade da solução

3.1 Análise inicial

Esta seção buscará apresentar condições sob as quais o problema (3) irá possuir solução única.

Para o desenvolvimento de tal argumentação, suponha que a solução buscada é k -esparsa, i.e., o vetor solução x possui no máximo k componentes não-nulas, sendo $k \ll m$.

Defina também Σ_k como sendo o conjunto de vetores k -esparsos em \mathbb{R}^n .

Vamos agora criar algumas impressões à respeito do núcleo de A . Seja x^* satisfazendo $Ax^* = b$. Sabemos que todas as outras soluções de $Ax = b$ são da forma $x^* + \eta$ sendo $\eta \in \mathcal{N}(A)$. Suponhamos também que $x^* \in \Sigma_k$ e vamos procurar condições para que x^* seja a única solução k -esparsa de $Ax = b$.

Supondo por contradição que existe um outro $x^{**} \in \Sigma_k$ tal que $Ax^{**} = b$, então temos que $A(x^* - x^{**}) = 0$, i.e., $x^* - x^{**} \in \mathcal{N}(A)$. Sabemos também que como $x^*, x^{**} \in \Sigma_k$, então a combinação linear $x^* - x^{**} \in \Sigma_{2k}$ (que também é não-nula).

Com isso concluímos que se $Ax = b$ possui mais do que um vetor k -esparsos como solução, então $\mathcal{N}(A)$ possui um vetor $2k$ -esparsos não-nulo.

Utilizando a contra-positiva desta afirmação nos fornece o seguinte lema.

Lema 1 *Suponha que $\Sigma_{2k} \cap \mathcal{N}(A) = \{0\}$, i.e., todos os elementos não-nulos no núcleo de A possuem ao menos $2k + 1$ componentes não-nulos. Então qualquer solução k -esparsa de $Ax = b$ é única.*

Uma variação da condição $\Sigma_{2k} \cap \mathcal{N}(A) = \{0\}$ é dada pelo seguinte lema.

Lema 2 *A condição $\Sigma_{2k} \cap \mathcal{N}(A) = \{0\}$ é válida se e somente se cada subconjunto de $2k$ colunas de A são linearmente independentes.*

Prova [1] Suponha que $\Sigma_{2k} \cap \mathcal{N}(A) = \{0\}$. Defina A_j como sendo a j -ésima coluna de A e $T \subseteq \{1, \dots, n\}$ seja qualquer subconjunto de índices com cardinalidade $|T| = 2k$. Considere o subconjunto $\{A_j : j \in T\}$ de $2k$ colunas de A . Se $\sum_{j \in T} x_j A_j = 0$ para alguns escalares x_j , então $Ax = 0$ para o vetor x com componentes x_j com $j \in T$ e $x_j = 0$ caso $j \notin T$. Assim $x \in \Sigma_{2k} \cap \mathcal{N}(A) = \{0\}$, que implica em $x = 0$. Portanto $x_j = 0$ para todo j e então $\{A_j : j \in T\}$ é um conjunto linearmente independente.

Para a volta, suponha cada subconjunto $\{A_j : j \in T\}$ de $2k$ colunas de A é linearmente independente. Considere um vetor $x \in \Sigma_{2k} \cap \mathcal{N}(A)$ e seja $T \subseteq \{1, \dots, n\}$ um conjunto qualquer de $2k$ índices tais que se $x_j \neq 0$, então $j \in T$ (e $x_j = 0$ se $j \notin T$). Nós usamos isso para formar o subconjunto $\{A_j : j \in T\}$ de $2k$ colunas de A que satisfaça

$$\sum_{j \in T} x_j A_j = Ax = 0,$$

porque $x \in \mathcal{N}(A)$. Mas $\{A_j : j \in T\}$ é linearmente independente por hipótese, então $x_j = 0$ para cada $j = 1, \dots, n$, i.e., $x = 0$. Portanto $\Sigma_{2k} \cap \mathcal{N}(A) = \{0\}$. \square

Porém, mesmo com ambos os lemas em mãos é computacionalmente impraticável verificar a condição $\Sigma_{2k} \cap \mathcal{N}(A) = \{0\}$, portanto precisamos de alguma outra estratégia.

3.2 Propriedade Isométrica Restrita

A condição $\Sigma_{2k} \cap \mathcal{N}(A)$ diz que não existe vetor não-nulo $2k$ -esparso que satisfaça $Ax = 0$. Não perdemos generalidade se supormos o mesmo para vetores unitários (com respeito à norma-2), já que se $x \neq 0$, então $Ax = 0$ se e somente se $Au = 0$ com $u = x/\|x\|_2$. Então iremos procurar uma condição para que não exista vetor unitário não-nulo $2k$ -esparso que satisfaça $Au = 0$.

É razoável assumir que neste caso, existe uma constante $c_1 > 0$ tal que todos vetores unitários u $2k$ -esparso satisficam $\|Au\|_2^2 > c_1$. Pois $Au = 0$ se e somente se $\|x\|_2^2 = 0$.

Sendo assim, podemos enunciar o seguinte lema.

Lema 3 *Se existe uma constante positiva c_1 tal que $c_1 \leq \|Au\|_2^2$ para todos os vetores unitários u $2k$ -esparso, então $\Sigma_{2k} \cap \mathcal{N}(A) = \{0\}$.*

Uma variação do Lema 3 que será útil a posteriori, quando formos analisar a efetividade da norma-1 para recuperar soluções esparsas pode ser construída considerando o fato de que se $c_1 \leq \|Au\|_2^2$ então sempre existirá c_2 tal que $\|Au\|_2^2 \leq c_2$ para qualquer vetor unitário $u \in \Sigma_{2k}$. Dessa forma, temos a seguinte desigualdade,

$$c_1 \leq \|Au\|_2^2 \leq c_2. \quad (4)$$

É razoável considerar que reescalando a matriz A por uma constante, a condição $\Sigma_{2k} \cap \mathcal{N}(A) = \{0\}$ continuará se verificando. Sendo assim, podemos multiplicar convenientemente a desigualdade (4) por $2/(c_1 + c_2)$, reescalar a matriz A pelo coeficiente $\sqrt{2/(c_1 + c_2)}$ e definir $\delta = (c_2 - c_1)/(c_2 + c_1)$, tendo assim, a desigualdade,

$$1 - \delta \leq \|Au\|_2^2 \leq 1 + \delta. \quad (5)$$

Note que como $c_2, c_1 > 0$, temos que $0 < \delta < 1$.

Com isso, podemos definir a propriedade isométrica restrita.

Definição 1 *Uma matriz $A \in \mathbb{R}^{m \times n}$ satisfaz a propriedade isométrica restrita de ordem k se existe alguma constante $\delta_K \in (0, 1)$ tal que*

$$1 - \delta_k \leq \|Au\|_2^2 \leq 1 + \delta_k,$$

para todos os vetores unitários u k -esparso.

Com esta definição, podemos criar um novo lema a partir do Lema 3.

Lema 4 *Se uma matriz A satisfaz a propriedade isométrica restrita de ordem $2k$ para algum $k \geq 1$, então $\Sigma_{2k} \cap \mathcal{N}(A) = \{0\}$ e qualquer vetor k -esparso é único.*

3.3 Propriedade Isométrica Restrita em matrizes aleatórias normais

Apesar de a propriedade isométrica restrita ser de difícil verificação, podemos desenvolver algo mais com a hipótese da matriz A possuir componentes aleatórios de distribuição normal.

Para tal situação, existe o seguinte teorema [1].

Teorema 1 *Seja A uma matriz $m \times n$ com $m = qn$ para algum $q \in (0, 1)$ e suas componentes sendo variáveis aleatórias independentes de uma distribuição normal de média 0 e variância $1/m$. Para qualquer $\epsilon \in (0, 1)$ fixado, $\delta \in (0, 1)$, e $m \geq 12/\delta$, a matriz A irá satisfazer a propriedade isométrica restrita de ordem k com constante $\delta_k = \delta$ com probabilidade de pelo menos $1 - \epsilon$ se n for escolhido grande o suficiente para satisfazer a desigualdade,*

$$-c_0qn + (k + 1/2) \ln(n) + c_1 \leq \ln(\epsilon),$$

onde $c_0 = \delta^2/144 - \delta^3/1296 > 0$ e $c_1 = k \ln\left(\frac{36\epsilon}{k\delta}\right) + \frac{1}{2} \ln(q/\pi)$.

Sendo assim, com o Teorema 1 podemos verificar que quando estamos lidando com matrizes de tamanho consideravelmente grande, teremos uma probabilidade quase certa de tal matriz possuir a propriedade isométrica restrita da ordem necessária para que a solução mais esparsa do problema $Ax = b$ seja única.

A demonstração do Teorema 1 é melhor abordada em [1].

4 Encontrando a solução esparsa de $Ax = b$ com a norma-1

O teorema que garante a suficiência de minimização da norma-1 para recuperação de sinais k -esparsos sob certas hipóteses é o seguinte. [1]

Teorema 2 *Seja A uma matriz $m \times n$ que satisfaz a propriedade isométrica restrita de ordem $3k$ com constante $\delta_{3k} < \frac{1}{3}$. Então, a solução de,*

$$\min \|x\|_1 \text{ s.a. } Ax = b,$$

recupera vetores k -esparsos.

(A demonstração do teorema é abordada em [1])

E pelo Lema 4, como A possui propriedade isométrica restrita de ordem $3k$, sabemos que tal vetor k -esparso é único.

Um fator a ser levado em conta ao tomar conhecimento de tal teorema, é de que tais condições garantem a convergência, porém ela ainda existe amplamente quando as hipóteses não são verificadas, garantindo assim um bom uso prático da detecção de compressão. Tomemos como exemplo o método de Newton, que possui algumas hipóteses de convergência, porém na prática tais hipóteses não são sempre verificadas e o método converge mesmo assim.

5 Considerações finais

O relatório seguiu o cronograma do projeto de forma satisfatória. A primeira parte do projeto, cujo este relatório representa, cobriu a parte teórica do tema. A segunda parte que seguirá, será responsável pelas aplicações práticas da detecção de compressão, utilizando imagens e/ou outros tipos de sinais digitais e também um mais amplo estudo à respeito de como utilizar programação linear para resolver o problema de minimização envolvido.

6 Referências Bibliográficas

- [1] K. Bryan & T. Leise, Making Do with Less: An Introduction to Compressed Sensing, **SIAM Review**, 55 (2013), 547-566.
- [2] E.J. Candès, J.K. Romberg & T. Tao, Stable Signal Recovery from Incomplete and Inaccurate Measurements, **Communications on Pure and Applied Mathematics**, 59 (2006), 1207-1223.
- [3] Y.C. Eldar & G. Kutyniok, **Compressed Sensing- Theory and Applications**, Cambridge, 2012.
- [4] S. Foucart & H. Rauhut, **A Mathematical Introduction to Compressive Sensing**, Birkhäuser, 2010.
- [5] Y. Zhang, Theory of Compressive Sensing via ℓ_1 -Minimization: a Non-RIP Analysis and Extensions, **Journal of the Operations Research Society of China**, 1 (2013), 79-105.
- [6] M. Elad, **Sparse and Redundant Representations**, Springer, 2010.
- [7] D. Donoho, For most large underdetermined systems of linear equations, the minimal ℓ_1 -norm solution is also the sparsest solution, **Comm. Pure Appl. Math.** 59 (2006), pp. 797-829.