

IDENTIFICAÇÃO DE MODELOS DINÂMICOS DE SATÉLITES COM GEOMETRIA VARIÁVEL ATRAVÉS DE REDES NEURAIS / *VARIABLE GEOMETRY SATELLITE DYNAMICS IDENTIFICATION WITH NEURAL NETWORKS*

VALDEMIR CARRARA & ATAIR RIOS NETO

Instituto Nacional de Pesquisas Espaciais – INPE/MCT

CEP 12201-970 CP 515 São José dos Campos, SP. E-mail: val@dem.inpe.br

Instituto de Pesquisa e Desenvolvimento, Universidade do Vale do Paraíba.

CEP 12245-720 São José dos Campos, SP. E-mail: atair@univap.br

Abstract

The use of neural networks for satellite attitude dynamics identification is addressed in this work. In order to validate this application, a spacecraft with a variable dynamic behavior due to articulated appendages fixed to the body was chosen. The differential equations therefore show the nonlinear dynamic effects to be identified by neural nets. In this work some of the main expressions that allow system modeling through neural nets as well as a least squares based training procedure are presented. A general method for obtaining the inertia tensor and center of mass of an articulated space device, is also explained together with the dynamic and cinematic differential equations. These formulations were used in attitude simulation for neural network system identification and control training's.

Keywords

Neural networks, satellite attitude, non-linear dynamics, system identification. Redes neurais, atitude de satélites, dinâmica não-linear, identificação de sistemas.

1. INTRODUÇÃO

Redes neurais artificiais têm sido utilizadas com êxito na solução de diversos problemas, que incluem desde aproximação de funções a reconhecimento de linguagem. Encontraram aplicações também em guiagem automática de veículos, análise de aplicações financeiras, layout de circuitos, síntese de voz, reconhecimento de imagens, previsão de variação cambial, controle de processos, sistemas de inspeção de qualidade, controle de robôs e tradução instantânea, entre outros (Demuth e Beale, 1992). O uso de redes em satélites artificiais ainda se encontra bastante limitado, com poucas referências (Vadali et alli, 1993, Rios Neto e Rao, 1996), porém existem possibilidades em áreas como: análise de falhas em subsistemas, controle de atitude, propagação e controle de órbita. O primeiro passo no caminho de um controlador de atitude baseado em redes neurais é obter um modelo de identificação da dinâmica. Este modelo fornece, a seguir, os recursos para o treinamento da rede de controle, com a dinâmica inversa do sistema (Narendra e Parthasarathy, 1990). O presente trabalho mostra a implementação da rede neural de identificação num satélite com geometria variável.

2. REDES NEURAIAS

Uma rede neural de alimentação direta (*feedforward*) consiste de uma transformação de mapeamento que leva n_0 elementos de sua entrada para uma saída composta de n_l elementos. Tipicamente, uma rede apresenta várias camadas onde cada camada é composta por vários neurônios artificiais. Na forma vetorial, a camada k da rede (n_k neurônios) pondera o vetor de entradas x^{k-1} com a matriz de pesos W^k e aplica uma *função de ativação* f^k em cada componente do vetor resultante:

$$x^k = f^k(\bar{x}^k) = f^k(W^k x^{k-1}). \quad (1)$$

onde a matriz de pesos W^k é composta por:

$$W^k = \begin{bmatrix} w_{11}^k & \cdots & w_{1n_{k-1}}^k & b_1^k \\ w_{21}^k & \cdots & w_{2n_{k-1}}^k & b_2^k \\ \vdots & & \vdots & \vdots \\ w_{n_k 1}^k & \cdots & w_{n_k n_{k-1}}^k & b_{n_k}^k \end{bmatrix}. \quad (2)$$

O parâmetro b^k é denominado patamar da função de ativação, e corresponde a uma entrada unitária, na última componente de x^k . Portanto, as dimensões de x^k e W^k são n_k+1 e $n_k \times n_{k-1}+1$, respectivamente, incluindo o patamar na matriz de pesos.

Entre as funções de ativação, é bastante empregada a função tangente hiperbólica dada por (Hunt et alli, 1992):

$$f(x) = \frac{1 - e^{-x}}{1 + e^x}. \quad (3)$$

Os pesos são geralmente estimados através de processos de *aprendizagem* ou *treinamento*, onde aplica-se um método iterativo baseado numa função objetivo a ser minimizada. Durante a fase de treinamento a rede aprende o comportamento do sistema ao redor dos pontos treinados a cada passo da iteração.

2.1 O método de mínimos quadrados

Os métodos de treinamento de redes neurais normalmente partem da minimização do erro apresentado na saída da rede como forma de obtenção dos pesos. Variam também conforme a forma de implementação: podem ser estimadores por lote, estimação estocástica (Rios Neto, 1994) ou por recursão, sendo que estes últimos são utilizados mais frequentemente, devido principalmente à facilidade de uso do método recursivo de retro-propagação do erro.

O algoritmo de retro-propagação obtém a derivada parcial do valor apresentado na saída da rede com relação a um determinado peso de uma das camadas anteriores. Se x^l representar o vetor de saídas da rede, então a derivada com relação ao peso w_{ij}^k da camada k vale:

$$\frac{\partial x^l}{\partial w_{ij}^k} = \Delta^k [0 \quad \cdots \quad x_j^{k-1} \quad \cdots \quad 0]^T, \quad (4)$$

onde o sinal \top significa o vetor ou matriz transposto, e Δ^k é a matriz de retro-propagação do erro, que pode ser posta numa forma recorrente:

$$\Delta^k = \Delta^{k+1} W^{k+1} F^k \quad (5)$$

com a condição para a camada de saída, l , de $\Delta^l = F^l$, onde F^k representa a matriz de derivadas da função de ativação da camada k :

$$F^k = \frac{df^k(\bar{x}^k)}{d\bar{x}^k} = \begin{bmatrix} f^{k'}(\bar{x}_1^k) & \cdots & 0 \\ \vdots & \ddots & \vdots \\ 0 & \cdots & f^{k'}(\bar{x}_{n_k}^k) \end{bmatrix} \quad (6)$$

Vale salientar que a matriz de derivadas da função de ativação, F^k , deveria possuir dimensão $n_{k-1}+1 \times n_{k-1}+1$, mas como o último elemento da diagonal é sempre nulo (por representar a derivada de uma constante), pode-se reduzir a dimensão da matriz de pesos (e também da matriz F^k) durante as multiplicações.

O método de treinamento de mínimos quadrados promove a atualização dos pesos através da minimização do erro quadrático médio apresentado na saída da rede, de forma recursiva. Para aplicar o método, os pesos da rede são dispostos num único vetor $w(t)$, referido ao instante, ou iteração, t . A atualização é feita na forma (Gelb, 1974; Chen e Billings, 1992):

$$\Delta w(t) = w(t) - w(t-1) = K(t) \varepsilon(t), \quad (7)$$

onde $\varepsilon(t)$ é o erro apresentado na saída da rede, ou seja, a diferença entre o valor de referência, ou desejado e aquele realmente apresentado na saída. $K(t)$ é o ganho de Kalman, obtido de:

$$K(t) = P(t-1) H(t)^\top [H(t) P(t-1) H(t)^\top + \lambda R(t)]^{-1} \quad (8)$$

onde $R(t)$ é a matriz de covariância do erro $\varepsilon(t)$, normalmente uma matriz identidade, $H(t)$ é a matriz de derivadas parciais do vetor de saída com relação ao vetor de pesos e $P(t)$ é matriz de covariância do erro de estimação. Como não existe propagação de equações dinâmicas neste processo, adota-se um *fator de esquecimento*, λ ($0 < \lambda < 1$), de forma a garantir que a covariância não diminua em demasia, conforme o sistema adquira conhecimento do vetor de pesos $w(t)$. A atualização da matriz de covariância se faz na forma:

$$P(t) = [1 - K(t) H(t)] P(t-1) / \lambda. \quad (9)$$

Normalmente os pesos são inicializados com uma distribuição aleatória uniforme e a matriz de covariância do erro $P(t)$ assume a forma diagonal, cujos elementos são fixados entre 10 e 10000 (Norgaard, 1995). A matriz de derivadas parciais pode ser decomposta nas matrizes H_i^k de derivadas parciais associadas ao neurônio i da camada k , obtida a partir do método de retro-propagação do erro:

$$H_i^k = \delta_i^k x^{k-1\top}. \quad (10)$$

Na expressão acima os vetores δ_i^k correspondem à i -ésima coluna i da matriz Δ^k .

3. MODELO DINÂMICO DO SATÉLITE

O movimento em atitude de um satélite em órbita da Terra pode ser aproximado por um corpo rígido e livre de torques. Na ausência de esforços externos, um corpo livre tende a conservar sua quantidade de movimento angular, ou momento angular L . A lei da conservação do momento angular afirma que a variação temporal do vetor momento angular em relação a um ponto fixo ou o centro de massa é igual à somatória dos torques externos (Wertz, 1978). Quando expresso no sistema de coordenadas fixo ao corpo do satélite, a variação do momento angular \dot{L}^o fica:

$$\dot{L}^o = I_o \dot{\omega}_o^o - \Omega(\omega_o^o) I_o \omega_o^o = N_{cont} + N_{pert} \quad (11)$$

onde I_o é a matriz de inércia do corpo, ω_o^o é a sua velocidade angular, referida no próprio sistema de coordenadas do corpo, e $\Omega(\cdot)$ é a matriz de operação do produto vetorial, dada por:

$$\Omega(\omega) = \begin{bmatrix} 0 & -\omega_z & \omega_y \\ \omega_z & 0 & -\omega_x \\ -\omega_y & \omega_x & 0 \end{bmatrix} \quad (12)$$

No caso de um satélite artificial, a resultante dos torques externos pode ser decomposta na parcela devida aos torques de perturbações ambientais, N_{pert} e a parcela devida aos torques externos oriundos do sistema de controle de atitude, N_{cont} . No entanto, se o satélite não for rígido, seja porque possui apêndices flexíveis ou geometria variável, as equações acima não são mais válidas. Para obter a equação da dinâmica do satélite, será suposto aqui que o mesmo é formado por diversos corpos rígidos, denominados elos, articulados com relação ao corpo principal do satélite através de juntas rotativas, e numerados seqüencialmente. A derivada do momento angular pode ser decomposta nos constituintes do satélite, na forma:

$$\dot{L}^o = \int_{V_o} \Omega(r_o^o) \ddot{r}_o^o dm_o + \sum_{k=1}^n \int_{V_k} \Omega(r_k^o) \ddot{r}_k^o dm_k . \quad (13)$$

onde os vetores r_o e r_k representam a posição do elemento de massa dm_o e dm_k , do corpo principal do satélite e do elo k , respectivamente, com relação ao centro de massa do conjunto, e expressos no sistema o , do corpo principal. As integrais são efetuadas em todo no volume V_o e V_k do satélite. Após compatibilizar as posições dos elementos de massa dos diversos elos, chega-se a uma forma modificada da equação de Euler:

$$\dot{L}^o = (I_o + J_n) \dot{\omega}_o^o + \Omega(\omega_o^o) I_o \omega_o^o + H_n \quad (14)$$

onde os termos J_n e H_n levam em conta não somente a inércia dos apêndices, mas também o efeito decorrente do mudança do centro de massa do conjunto, devido ao movimento dos elos:

$$\begin{aligned}
 J_n = & \sum_{k=1}^n \left(A_{k,o} I_k A_{k,o}^T - m_k \Omega(a_{ok}^o - a_{ko}^o) \Omega(a_{ok}^o - a_{ko}^o) \right) + \\
 & + \sum_{k=1}^n \left(m_k \Omega(a_{ok}^o - a_{ko}^o) \right) \sum_{k=1}^n \left(\mu_k \Omega(a_{ok}^o - a_{ko}^o) \right)
 \end{aligned} \quad (15)$$

sendo I_k a matriz de inércia do elo k com relação ao sistema k ; m_k a massa deste elo; $A_{k,o}$ a matriz de rotação entre o sistema de coordenadas do elo k e o corpo principal; a_{ok} o vetor posição da articulação deste elo com relação à origem do sistema de coordenadas do corpo principal e a_{ko} a posição desta junta com relação à origem do sistema de coordenadas deste elo. μ_k é a massa reduzida do elo k , isto é a massa deste elo dividida pela massa total do satélite. O vetor H_n é obtido de:

$$\begin{aligned}
 H_n = & \sum_{k=1}^n \left[\Omega(\omega_o^o + \omega_k^o) A_{k,o} I_k A_{k,o}^T (\omega_o^o + \omega_k^o) + A_{k,o} I_k A_{k,o}^T (\dot{\omega}_k^o + \Omega(\omega_o^o) \omega_k^o) \right] + \\
 & + \sum_{k=1}^n m_k \Omega(a_{ok}^o - a_{ko}^o) \beta_k - \left(\sum_{k=1}^n m_k \Omega(a_{ok}^o - a_{ko}^o) \beta_k \right) \sum_{k=1}^n \mu_k \beta_k,
 \end{aligned} \quad (16)$$

e o termo β_k vale:

$$\begin{aligned}
 \beta_k = & \Omega(\omega_o^o) \Omega(\omega_k^o) (a_{ok}^o - a_{ko}^o) - \Omega(\omega_o^o) \Omega(\omega_k^o) a_{ko}^o - \\
 & - \Omega(\omega_k^o) \Omega(\omega_o^o + \omega_k^o) a_{ko}^o + \Omega(a_{ko}^o) \left(\Omega(\omega_o^o) \omega_k^o + \dot{\omega}_k^o \right)
 \end{aligned} \quad (17)$$

Note que as velocidades angulares ω_k^o e acelerações $\dot{\omega}_k^o$ das juntas articuladas, expressas no sistema do corpo principal, são conhecidas pois não se trata de articulações livres. Utilizou-se, no exemplo mostrado aqui, o modelo do Satélite de Sensoriamento Remoto (SSR) da Missão Espacial Completa Brasileira (MECB), visto na Figura 1. O satélite SSR é




Figura 1: Satélite de sensoriamento remoto.

formado por um corpo principal, onde se localizam os instrumentos e equipamentos para a operação, e três painéis recobertos por células solares, responsáveis pelo suprimento de energia elétrica para os aparelhos de bordo. O posicionamento dos painéis é concebido visando o melhor aproveitamento da energia disponível na órbita solssíncrona deste satélite. Devido ao tamanho dos painéis e seu posicionamento quando em órbita, estes ficam presos ao corpo do satélite durante o lançamento, e são abertos após a injeção na órbita.

Uma vez em órbita, parafusos pirotécnicos providenciam a liberação dos painéis através de comandos do sistema de controle. Uma vez liberados, os painéis são impulsionados por molas de torção, e um dispositivo de trava prende-os na posição de operação.

4. A IDENTIFICAÇÃO DO SISTEMA DINÂMICO

Na identificação da dinâmica do SSR, utilizou-se como entradas da rede os sinais dos dois sensores de atitude: sensor solar e magnetômetro, ambos de três eixos. Foi necessário,

também, prover à rede duas informações atrasadas dos sinais destes sensores. A alteração no comportamento dinâmico do satélite introduzida pela abertura dos painéis foi fornecida através de um sensor de posição que fornece o ângulo de abertura a cada instante. Foi fornecido, também para esta variável, dois valores atrasados. O SSR deverá utilizar motores de hidrazina como atuadores, na fase de aquisição de atitude. Cada motor consegue fornecer 0,19 Nm de torque. O ciclo de controle, ou seja, o intervalo de tempo entre duas leituras dos sensores e comando dos atuadores será considerado como de 1 segundo. As informações atrasadas dos sinais dos motores nos três eixos do satélite nos instantes $t-1$ e $t-2$ também fazem parte do conjunto de valores de entrada da rede. As saídas da rede de identificação são, naturalmente, estimativas dos próprios sinais dos sensores: magnetômetro de três eixos e sensor solar de dois eixos, no instante $t+1$.

Os sinais de saída foram normalizados entre -5 e 5, por dois motivos: primeiro, para aproximarem-se dos valores analógicos dos sensores; segundo, porque as componentes do erro apresentado na saída da rede devem ser compatíveis entre si em termos de ordem de magnitude, para que o treinamento não favoreça os sinais de maior amplitude.

Admitiu-se que a atitude inicial fosse qualquer, escolhida aleatoriamente no início de cada simulação. A velocidade angular inicial é também escolhida aleatoriamente, porém limitada a 5 rotações por minuto.

Os motores foram acionados segundo uma distribuição de Poisson, com probabilidade de 8% de estarem acionados em cada instante e com duração média de 1 segundo. A simulação da abertura dos painéis foi realizada sempre no meio do intervalo de simulação, ou seja, após 100 segundos de treinamento. Após alguns testes, obteve-se resultados com apenas 8 neurônios na camada oculta, com precisões compatíveis com o ruído apresentado pelo magnetômetro e sensor solar (que conseguem, no máximo, precisões de 1%), correspondendo a um erro quadrático médio da ordem $2,5 \cdot 10^{-3}$.

Utilizou-se no treinamento um fator de esquecimento λ de 0,996; magnitude inicial da matriz de covariância de 10, amplitude inicial dos pesos de 0,1 com distribuição uniforme. A Figura 2 mostra a evolução do erro quadrático médio em função do número de treinamentos. Cada conjunto de treinamento é composto por uma simulação contendo 200 pontos (um a cada segundo de propagação). Com cerca de 40 simulações, atingiu-se a precisão desejada para a identificação do modelo direto. Após o treinamento, foram realizados testes da rede utilizando condições iniciais nas quais ela não havia sido treinada. Verificou-se assim que o erro permaneceu próximo aos valores obtidos durante o treinamento. As figuras que seguem mostram uma comparação entre a saída apresentada pela rede neural e o resultado da propagação da dinâmica do satélite em um destes testes.

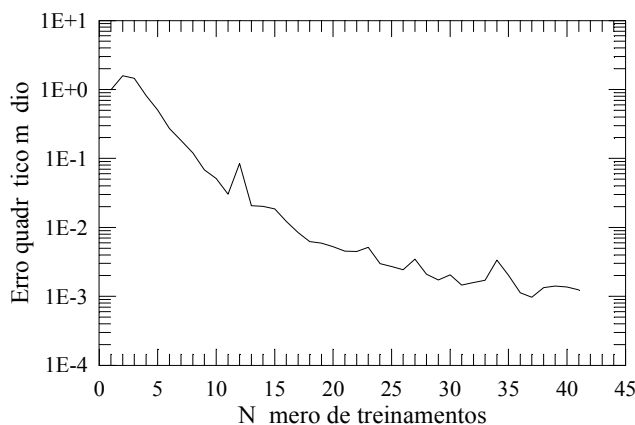


Figura 2: Treinamento da rede de identificação.

Na Figura 3 são mostrados os 3 sinais do sensor solar e na Figura 4 os sinais do magnetômetro, ambos superpostos à saída correspondente da rede. As diferenças são quase imperceptíveis nas figuras. Os erros são mostrados respectivamente nas Figuras 5 e 6. Percebe-se que embora em alguns pontos o erro supere o limite estabelecido, na média a diferença permanece confinada dentro da precisão desejada, mesmo neste caso onde a rede não foi treinada.




Figura 3: Medidas simuladas do sensor solar e da rede neural.




Figura 4: Medidas simuladas do magnetômetro e da rede neural.




Figura 5: Erro apresentado pela rede neural na medida do sensor solar.

5. CONCLUSÕES

Mostrou-se, neste trabalho, que redes neurais podem ser utilizadas em modelos dinâmicos de satélites com geometria variável. Embora a dinâmica da atitude seja não-linear, e a introdução da geometria variável dada pela abertura dos painéis solares seja um agravante, uma rede com apenas 8 neurônios na camada oculta foi capaz de atingir um erro menor que 1%. O método de treinamento utilizado, mínimos quadrados recursivos, mostrou uma convergência bastante superior com relação ao método do gradiente. Com apenas 40 iterações atingiu-se a precisão requerida. O método dos mínimos quadrados apresenta, contudo, um

tempo de processamento bastante elevado, em virtude da complexidade do algoritmo. Ainda assim, ele é mais eficiente na convergência, e menos suscetível a ficar preso em mínimos locais do que o método do gradiente.




Figura 6: Erro apresentado pela rede neural na leitura do magnetômetro.

Em virtude da impossibilidade de treinar a rede neural de controle utilizando o próprio satélite (treinamento *on-line*), foram obtidas relações cinemáticas e dinâmicas para simulação em computador da atitude do satélite antes, durante e após a abertura dos painéis. Ainda assim, o processo de treinamento pode ser validado, e no futuro todo o treinamento poderá ser efetuado com o satélite já em órbita, ou de forma adaptativa, isto é, com parte do treinamento efetuado em Terra, por simulação, e aperfeiçoado após o lançamento.

6. REFERÊNCIAS

- CHEN, S.; BILLINGS, S. A. Neural networks for nonlinear dynamic system modelling and identification. *International Journal of Control*, 56 (2):319-346, 1992.
- DEMUTH, H.; BEALE, M. *Neural network toolbox user's guide*. Natick, MA. Math Works, 1992.
- GELB, A. *Applied Optimal Estimation*. The M.I.T. Press, MA, 1974.
- HUNT, K. J.; SBARBARO, D.; ZBIKOWSKI, R.; GAWTHROP, P. J. Neural networks for control systems - a survey. *Automatica*. 28 (6):1083-1112, 1992.
- NARENDRA, K. S.; PARTHASARATHY, K. Identification and control for dynamic systems using neural networks. *IEEE Transactions on Neural Networks*, 1, 1990.
- NORGAARD, M. *Neural Network Based System Identification Toolbox*. Institute of Automation, Technical University of Denmark, 1995 (Technical Report 95-E-773).
- RIOS NETO, A. *Stochastic parameter estimation neural nets supervised learning approach*. Proceedings of the 1st Brazilian Congress in Neural Nets, Itajubá, MG, 1994.
- RIOS NETO, A.; RAO, K. R. *A study on the on board artificial satellite orbit propagations using artificial neural networks*. Proceedings of the 11th International Astronautics Symposium, Gifu, Japan, 1996.
- VADALI, S. R.; KRISHNAN, S.; SINGH, T. Attitude control of spacecraft using neural networks. *Advances in the astronautical sciences*. American Astronautical Society. Vol. 82, Part 1, 1993.
- WERTZ, J. R. *Spacecraft attitude determination and control*, London, D. Reidel, 1978 (Astrophysics and Space Science Library).

Redes neurais artificiais têm sido utilizadas com êxito na solução de diversos problemas, que incluem desde aproximação de funções a reconhecimento de linguagem escrita e falada. Encontraram aplicações também em sistemas de guiagem automática de veículos, análise de aplicações financeiras, layout de circuitos eletrônicos, síntese de voz, visão artificial, reconhecimento de padrões em imagens, previsão de variação cambial, controle de processos em manufatura, sistemas visuais de inspeção de qualidade, controle de manipuladores robóticos e tradução instantânea, entre outros (Demuth e Beale, 1992). O uso de redes em satélites artificiais ainda se encontra bastante limitado, e poucas são as referências (Vadali et alli, 1993, Rios Neto e Rao, 1996), porém existem possibilidades em áreas como: análise de falhas em subsistemas, controle de atitude, propagação e controle de órbita. O primeiro passo no caminho de um controlador de atitude baseado em redes neurais é obter um modelo de identificação da dinâmica. Este modelo fornece, a seguir, os recursos para o treinamento da rede de controle, com a dinâmica inversa do sistema (Narendra e Parthasarathy, 1990). O presente trabalho mostra a implementação da rede neural de identificação num satélite com geometria variável (cuja matriz de inércia e centro de massa varia com o tempo).

3. IDENTIFICAÇÃO DE MODELOS DINÂMICOS

Quando se utilizam redes do tipo estática, o comportamento dinâmico do sistema deve ser fornecido através de informações “atrasadas” de seu estado. O número destas informações determina o grau de aproximação da rede, mas é certo que esta quantidade se relaciona com a ordem do sistema. Na verdade, a rede interpreta as informações atrasadas do estado como avaliações das derivadas naquele instante (Narendra e Parthasarathy, 1990).




Figura 7 - Identificação de modelo direto.

Na identificação do sistema, a rede é treinada para se comportar como o sistema real, com entradas e saídas idênticas ao modelo físico. Nesta modelagem, rede e sistema são postos em paralelo, e utiliza-se o erro entre as suas saídas como estímulo do treinamento, conforme a Figura 7. As entradas da rede são compostas não apenas pelo sinal de controle (entrada para o sistema) mas também as observações adquiridas da planta (linha tracejada da Figura 7). Devem ser fornecidos à rede n valores atrasados das observações (ou do estado) e k valores do controle.

Neste caso a saída $y^m(t)$ da rede assume a forma da função discreta dada por:

$$y^m(t+1) = f_m(y^p(t), y^p(t-1), \dots, y^p(t-n), u(t), u(t-1), \dots, u(t-k)) \quad (18)$$