



UNIVERSIDADE FEDERAL DE PERNAMBUCO
CENTRO DE TECNOLOGIA E GEOCIÊNCIAS
DEPARTAMENTO DE ENGENHARIA ELÉTRICA
CURSO DE ENGENHARIA ELÉTRICA

HELOISA BEZERRA NEVES

**USO DE REDES NEURAIS PARA PREVISÕES DE VAZÕES NOS
RESERVATÓRIOS DE SOBRADINHO E FURNAS**

Recife
2021

HELOISA BEZERRA NEVES

**USO DE REDES NEURAIS PARA PREVISÕES DE VAZÕES NOS
RESERVATÓRIOS DE SOBRADINHO E FURNAS**

Trabalho de Conclusão de Curso
apresentado ao Curso de Engenharia
Elétrica da Universidade Federal de
Pernambuco, como requisito parcial para a
obtenção do grau de Bacharel em
Engenharia Elétrica.

Orientador: Prof. Dr. Ronaldo Ribeiro Barbosa de Aquino.

Recife
2021

Catálogo na fonte:
Bibliotecária Sandra Maria Neri Santiago, CRB-4 / 1267

N518u	Neves, Heloisa Bezerra. Uso de redes neurais para previsões de vazões nos reservatórios de sobradinho e furnas / Heloisa Bezerra Neves. – 2021. 40 f.: il., figs., gráfs., tabs., abrev. e siglas. Orientador: Prof. Dr. Ronaldo Ribeiro Barbosa de Aquino. TCC (Graduação) – Universidade Federal de Pernambuco. CTG. Departamento de Engenharia Elétrica, Recife, 2021. Inclui referências e apêndices. 1. Engenharia elétrica. 2. Previsão de vazão. 3. Rede neural artificial. 4. Sistema hidroelétrico. I. Aquino, Ronaldo Ribeiro Barbosa de (Orientador). II. Título. 621.3 CDD (22. ed.)	UFPE BCTG/2022-199
-------	--	----------------------------------

HELOISA BEZERRA NEVES

**USO DE REDES NEURAIS PARA PREVISÕES DE VAZÕES NOS
RESERVATÓRIOS DE SOBRADINHO E FURNAS**

Trabalho de Conclusão de Curso
apresentado ao Curso de Engenharia
Elétrica da Universidade Federal de
Pernambuco, Centro de Tecnologia e
Geociências, como requisito parcial para a
obtenção do grau de Bacharel em
Engenharia Elétrica.

Aprovado em: 21/12/2021.

BANCA EXAMINADORA

Prof. Dr. Ronaldo Ribeiro Barbosa de Aquino (Orientador)
Universidade Federal de Pernambuco.

Prof. Dr. Pedro André Carvalho Rosas (Examinador Interno)
Universidade Federal de Pernambuco

Prof. Dr. Zanoni Dueire Lins (Examinador Interno)
Universidade Federal de Pernambuco

RESUMO

Este trabalho apresenta as previsões de vazões nos reservatórios de Sobradinho e Furnas, localizados na bacia do São Francisco e bacia do Rio Grande, respectivamente. Foi utilizado o modelo baseado em RNA (Redes Neurais Artificiais), através do *software* MATLAB (*Matrix Laboratory*) e a interface gráfica *NNTool*. As redes neurais artificiais foram selecionadas para conjecturar a vazão mensal com horizonte de um ano dos reservatórios. Os dados utilizados de vazões foram provenientes do Operador Nacional do Sistema Elétrico (ONS), órgão responsável pela geração e transmissão de energia elétrica no Sistema Interligado Nacional (SIN), no período de 1931 a 2016, com a finalidade de realizar os ajustes dos modelos. Para a análise do desempenho das previsões foram utilizados os resultados das vazões do período de 2017 a 2019. Por meio desta análise, este trabalho tem como objetivo contribuir com os debates acerca das previsões de vazão das usinas hidroelétricas brasileiras, que compõem a principal forma de geração de energia elétrica do país.

Palavras-chave: previsão de vazão; rede neural artificial; sistema hidroelétrico.

ABSTRACT

This work presents the flow forecasts in the Sobradinho and Furnas reservoirs, located in the São Francisco basin and Rio Grande basin, respectively. The model based on ANN (Artificial Neural Networks) was used, through the MATLAB (Matrix Laboratory) software and the NNTool graphical interface. Artificial neural networks were selected to conjecture the monthly flow with a one-year horizon of the reservoirs. The flow data used came from the National Electric System Operator (ONS), the body responsible for the generation and transmission of electricity in the National Interconnected System (SIN), in the period from 1931 to 2016, in order to make adjustments to the models. For the analysis of the performance of the forecasts, the results of the flows from the period from 2017 to 2019 were used. Through this analysis, this work aims to contribute to the debates about the flow forecasts of Brazilian hydroelectric plants, which make up the main form of electricity generation in the country.

Keywords: flow forecast; artificial neural network; hydroelectric system.

LISTA DE FIGURAS

Figura 1 - Energia Armazenada - Sudeste/Centro-Oeste.....	12
Figura 2 - Localização da bacia do São Francisco, do reservatório Sobradinho (triângulo) e dos reservatórios à jusante (círculos).....	14
Figura 3 - Localização da bacia do Rio Grande	15
Figura 4 - Modelo de um neurônio artificial	18
Figura 5 - Funções de ativação	19
Figura 6 - Diagrama de blocos da aprendizagem supervisionada.....	20
Figura 7 - Diagrama de blocos da aprendizagem não supervisionada.....	21
Figura 8 - Elementos da configuração utilizando cossenos e senos	29

LISTA DE GRÁFICOS

Gráfico 1 - Histórico da EAR do Subsistema Sudeste/Centro-Oeste	13
Gráfico 2 - Histórico de vazões médias de Sobradinho.....	24
Gráfico 3 - Histórico de vazões médias de Furnas.....	24
Gráfico 4 - Erro da previsão de Sobradinho para os anos 2017,2018 e 2019.....	33
Gráfico 5 - Vazões reais e previstas de Sobradinho	33
Gráfico 6 - Erro da previsão de Furnas para os anos 2017,2018 e 2019.....	34
Gráfico 7 - Vazões reais e previstas de Furnas.....	34

LISTA DE TABELAS

Tabela 1 - Erros obtidos na validação de Sobradinho.....	31
Tabela 2 - Erros obtidos na validação de Furnas	32

LISTA DE ABREVIATURAS E SIGLAS

BEN	Balanço Energético Nacional
EAR	Energia Armazenada
MAPE	Mean Absolute Percentage Error (Erro Médio Absoluto Percentual)
MATLAB	Matrix Laboratory
MLP	Multilayer Perceptron (Perceptron Multicamadas)
MSE	Mean Squared Error (Erro Médio Quadrático)
ONS	Operador Nacional do Sistema Elétrico
PEN	Plano de Operação Energética
RNA	Redes Neurais Artificiais
SIN	Sistema Interligado Nacional

SUMÁRIO

1	INTRODUÇÃO	12
1.1	USINA HIDRELÉTRICA DE SOBRADINHO	13
1.2	USINA HIDRELÉTRICA DE FURNAS	15
1.3	OBJETIVO	16
1.3.1	Objetivos Específicos	16
2	INTELIGÊNCIA ARTIFICIAL	17
2.1	REDES NEURAIS ARTIFICIAIS	17
2.1.1	Neurônio Artificial	17
2.1.2	Função de Ativação	18
2.1.3	Processos de Aprendizagem	19
2.1.3.1	Aprendizagem supervisionada	20
2.1.3.2	Aprendizagem não supervisionada	20
2.1.4	Perceptrons de Múltiplas Camadas	21
3	METODOLOGIA	23
3.1	METODOLOGIA APLICADA	23
3.1.1	Tratamento dos Dados	23
3.1.2	Normalização dos Dados	24
3.1.3	Separação dos Dados para Treinamento e Validação	25
3.2	EXPERIMENTOS PARA ESCOLHA DA REDE NEURAL	25
3.2.1	Análise de Desempenho	26
3.2.2	Critérios de Parada dos Treinamentos	26
3.3	SELEÇÃO DA REDE NEURAL	27
4	MODELO DE PREVISÃO	28
4.1	HORIZONTES PARA PREVISÃO DE VAZÃO	28
4.2	CONFIGURAÇÃO PARA PREVISÃO UTILIZANDO RNA	28
5	RESULTADOS	31
5.1	RESULTADOS DAS VALIDAÇÕES DE TREINAMENTO	31
5.2	RESULTADOS DAS PREVISÕES	32
6	CONCLUSÕES	35
6.1	TRABALHOS FUTUROS	35
	REFERÊNCIAS	36

APÊNDICE A – SÉRIE MENSAL DE AFLUÊNCIAS DO RESERVATÓRIO DE SOBRADINHO NO PERÍODO DE 1931-2016	37
APÊNDICE B – SÉRIE MENSAL DE AFLUÊNCIAS DO RESERVATÓRIO DE FURNAS NO PERÍODO DE 1931-2016.....	39


1 INTRODUÇÃO

A matriz elétrica brasileira é composta predominantemente por fonte hídrica, representando 65,2%, segundo dados do Balanço Energético Nacional (BEN) 2021. As usinas hidrelétricas são componentes do Sistema Interligado Nacional (SIN) e seu planejamento de operação é responsabilidade do Operador Nacional do Sistema Elétrico (ONS). O planejamento energético é essencial para o atendimento adequado da demanda de energia e depende da série histórica de vazões para análise e tomada de decisões relacionadas à operação dos reservatórios.

O Plano de Operação Energética (PEN) 2020/2024 realizou uma avaliação probabilística da Energia Armazenada (EAR) para o ano de 2021, mostrada na Figura 1. A simulação indicou, para o subsistema Sudeste/Centro-Oeste, valores médios de energia armazenada para o final do período úmido (abril) da ordem de 73% da $EAR_{máx}$, chegando ao final de novembro de 2021 com uma probabilidade de 0,8% de ocorrência de níveis iguais ou inferiores a 10% da $EAR_{máx}$.


O Gráfico 1 mostra os valores reais da EAR para o intervalo de janeiro de 2020 até dezembro de 2021, de modo que é possível comparar com a previsão do PEN e perceber que as dificuldades para realizar previsões são inerentes ao modelo utilizado.

Figura 1 - Energia Armazenada - Sudeste/Centro-Oeste



Fonte: ONS (2020)

Gráfico 1 - Histórico da EAR do Subsistema Sudeste/Centro-Oeste



Fonte: A autora (2021)

Nesse sentido, o uso de redes neurais artificiais (RNA) contribui para a realização das previsões de vazão, uma vez que as usinas hidroelétricas possuem características de produção não-linear e suas vazões afluentes são variáveis aleatórias, sendo assim um problema estocástico e não-linear. (BALLINI, 2001).

1.1 USINA HIDRELÉTRICA DE SOBRADINHO

O reservatório Sobradinho está localizado na bacia do São Francisco, sendo o mais importante reservatório da região Nordeste para fins de irrigação, consumo de água e geração hidroelétrica. A Figura 2 mostra a localização da Bacia do São Francisco e do reservatório Sobradinho, que está localizado no baixo São Francisco e possui uma área de drenagem de cerca de 498.425 km².

Figura 2 - Localização da bacia do São Francisco, do reservatório Sobradinho (triângulo) e dos reservatórios à jusante (círculos)



Fonte: Lima (2007)


A montante está localizado o reservatório Três Marias, importante regulador das afluições ao Sobradinho. A área incremental de drenagem entre Três Marias e Sobradinho é de aproximadamente 447.865 km². O máximo volume de armazenamento do Sobradinho é de 28.669 hm³, o que leva a uma capacidade máxima de geração elétrica de 1.050 MW. A água liberada por Sobradinho é reaproveitada em mais sete usinas hidroelétricas, que tem uma pequena capacidade de armazenamento de água, mas aumentam a máxima capacidade de geração de energia para cerca de 9.800 MW. Devido a sua localização equatorial, o reservatório de Sobradinho apresenta uma alta taxa de evaporação, que pode atingir 480 m³/s durante o dia. Seu uso também inclui controle de cheias, o que reforça a necessidade de uma ótima política operacional. (LIMA, 2007)

O ONS disponibiliza a série mensal de afluições do reservatório de Sobradinho, correspondente ao período 1931-2016 (APÊNDICE A). A estação chuvosa inicia-se aproximadamente em novembro e termina em abril. Os meses remanescentes representam a estação seca. As maiores afluições são observadas em janeiro e março.

1.2 USINA HIDRELÉTRICA DE FURNAS

O reservatório de Furnas localiza-se na bacia do Rio Grande, Figura 3, em Minas Gerais. A bacia afluente ao reservatório de Furnas compreende uma área de 51.900 km². A bacia do Rio Grande tem grande importância no contexto da geração hidroelétrica brasileira, com uma capacidade instalada de 7.722 MW, representando 11,7% da capacidade instalada do país. Destacam-se na bacia as usinas hidroelétricas de Marimbondo, Água Vermelha, Estreito e Furnas, cada uma com uma potência instalada superior a 1.000 MW.

Figura 3 - Localização da bacia do Rio Grande



Fonte: FINEP (2007)

A vazão do Rio Grande afluente a Furnas tem uma forte variação sazonal, como resultado do inverno seco e do verão chuvoso. A vazão afluente varia entre valores próximos a 350 m³/s, no período de estiagem, e valores tipicamente superiores a 2.000 m³/s no período de verão, com algumas cheias superiores a 4.000 m³/s (BRAVO, 2008).

A série mensal de afluições do reservatório de Furnas, correspondente ao período 1931 até 2016, encontra-se no APÊNDICE B.

1.3 OBJETIVO

Analisar, através de Redes Neurais Artificiais (RNA), as previsões de vazão dos reservatórios de Sobradinho e Furnas.

1.3.1 Objetivos Específicos

Apresentar os principais conceitos sobre as RNA e sua importância na previsão de vazão, descrever a metodologia utilizada para a previsão, apresentando o método para tratamento de dados, escolha da melhor arquitetura e avaliação de desempenho através do MAPE (*Mean Absolute Percentage Error*). Descrever o modelo utilizado e apresentar os resultados obtidos, bem como as considerações finais do trabalho.

2 INTELIGÊNCIA ARTIFICIAL

Este capítulo apresenta os principais conceitos sobre redes neurais artificiais e explica a escolha da arquitetura para ser aplicada na previsão de vazão dos reservatórios de Sobradinho e Furnas.

2.1 REDES NEURAIS ARTIFICIAIS

Segundo Haykin (2001) uma rede neural pode ser definida como um sistema paralelo constituído de unidade de processamento simples e que possui a tendência de armazenar conhecimentos e torná-los disponíveis para uso. Pode-se dizer que uma rede neural se assemelha ao cérebro humano em dois aspectos:

1. O conhecimento é assimilado pela rede a partir de seu ambiente por meio de um processo de aprendizagem. O procedimento realizado no processo de aprendizagem é chamado de algoritmo de aprendizagem, e tem a função de alterar os pesos sinápticos da rede de modo a alcançar o objetivo desejado.
2. As conexões entre os neurônios, conhecidas como pesos sinápticos, são utilizadas para armazenar o conhecimento adquirido.

Além da vantagem de ter uma estrutura maciçamente paralelamente distribuída, a rede neural possui a habilidade de generalização, o que garante a capacidade de produzir saídas adequadas para entradas que não estavam presentes no conjunto de treinamento (aprendizagem).


2.1.1 Neurônio Artificial

O neurônio artificial, representado na Figura 4, é uma unidade de processamento de informações, que é essencial para a operação de uma rede neural, e tem três elementos básicos:

1. Conjunto de sinapses ou elos de conexão caracterizado por um peso ou força própria. Especificamente, um sinal x_j na entrada da sinapse j conectada ao neurônio k é multiplicado pelo peso sináptico w_{kj} ;
2. Somador para somar os sinais de entrada, ponderados pelas respectivas sinapses do neurônio;

3. Função de ativação, também chamada de função restritiva, para restringir a amplitude da saída de um neurônio.

Figura 4 - Modelo de um neurônio artificial



Fonte: Tavares (2009)

O neurônio artificial possui um bias, representado no modelo por w_{k0} , cuja função é aumentar ou diminuir a entrada líquida da função de ativação, dependendo se ele é positivo ou negativo, respectivamente.

Pode-se descrever um neurônio k de acordo com as Equações 1 e 2,

$$v_k = \sum_{j=1}^m w_{kj} x_j + b_k \quad (1)$$

$$y_k = \varphi(v_k) \quad (2)$$


onde $x_1, x_2, x_3, \dots, x_n$ são os sinais de entrada; $w_{k1}, w_{k2}, w_{k3}, \dots, w_{kn}$ são os pesos sinápticos associados ao neurônio k , definindo um campo local induzido v_k como sendo a saída do combinador linear que será aplicado à função de ativação $\varphi(\cdot)$, obtendo a saída do neurônio (y_k).

2.1.2 Função de Ativação

As funções de ativação normalmente são funções não lineares, o que transforma as redes neurais em um sistema computacional não-linear, capaz de

representar problemas mais complexos (SILVEIRA, 2010). A Figura 5 representa as funções de ativação mais utilizadas.

Figura 5 - Funções de ativação



Fonte: Tavares (2009)

A função utilizada foi a tangente, pois é eficiente na questão da não-linearidade e é centrada em zero, sendo mais atraente que a função sigmoide para servir de ativação às camadas ocultas das redes neurais artificiais.

2.1.3 Processos de Aprendizagem

Uma rede neural aprende sobre o seu ambiente através de um processo iterativo de ajustes aplicados a seus pesos sinápticos e níveis de bias. Dessa forma, tem-se, idealmente, uma rede mais informada sobre o seu ambiente após as interações de aprendizagem.

Segundo Mendel e McClaren (1970): “*Aprendizagem é o processo pelo qual os parâmetros de uma rede neural são ajustados através de uma forma continuada de estímulo pelo ambiente no qual a rede está operando*”.


2.1.3.1 Aprendizagem supervisionada

Na aprendizagem supervisionada, também denominada aprendizagem com um professor, as entradas e saídas são fornecidas por um supervisor externo (professor). Considerando que o professor e a rede neural são expostos ao conjunto de treinamento retirado do ambiente, o professor, por ter conhecimento prévio, é capaz de fornecer à rede neural uma resposta desejada para o conjunto de treinamento.

Os parâmetros da rede são ajustados sob a influência combinada do conjunto de treinamento e o sinal de erro. O sinal de erro é definido como a diferença entre a resposta desejada e a resposta real da rede. Estes ajustes são realizados passo a passo, iterativamente, com o objetivo de fazer a rede neural emular o professor. Assim, o conhecimento do ambiente disponível ao professor é transferido a rede neural através de treinamento, da forma mais completa possível. Quando esta condição é alcançada, pode-se dispensar o professor e deixar a rede neural lidar com o ambiente por si mesma.

A Figura 6 mostra um diagrama de blocos desta forma de aprendizagem.

Figura 6 - Diagrama de blocos da aprendizagem supervisionada




Fonte: Haykin (2001)

2.1.3.2 Aprendizagem não supervisionada

Na aprendizagem não supervisionada não há um professor para supervisionar o processo de aprendizado. Este paradigma é indicado na Figura 7.

Figura 7 - Diagrama de blocos da aprendizagem não supervisionada



Fonte: Tavares (2009)

São dadas as condições para realizar uma medida independente da tarefa da qualidade da representação que a rede deve aprender, e os parâmetros livre da rede são otimizados em relação a esta medida. Dessa forma, a rede desenvolve a habilidade de formar representações internas para codificar as características de entrada, e assim, criar novas classes.

A regra de aprendizagem competitiva é um exemplo do aprendizado não supervisionado. Pode-se usar uma rede neural composta de duas camadas - camada de entrada e camada competitiva. A camada de entrada recebe os dados disponíveis e a camada competitiva é formada por neurônios que competem entre si para serem ativados.

Durante o treinamento, os neurônios que não se tornaram ativos com determinado padrão de entrada tem seus pesos ajustados, de forma que tenha maior probabilidade de se tornar ativo quando for estimulado por um padrão semelhante. Os neurônios que não foram ativados, podem ser ajustados ou não, dependendo do seu grau de vizinhança com o neurônio ativo.

2.1.4 Perceptrons de Múltiplas Camadas

A rede consiste em um conjunto de unidades sensoriais (nós de fonte) que constituem a camada de entrada, uma ou mais camadas ocultas de nós computacionais e uma camada de saída de nós computacionais. O sinal de entrada se propaga para frente através da rede, camada por camada.

Os perceptrons de múltiplas camadas têm sido aplicados com sucesso para resolver diversos problemas difíceis, através do seu treinamento de forma

supervisionada com um algoritmo muito popular conhecido como algoritmo de retropropagação de erro (*error back-propagation*). A aprendizagem por retropropagação de erro consiste em dois passos através de diferentes camadas da rede: um passo à frente, a propagação, e um passo para trás, a retropropagação.

No passo para frente, um padrão de atividade (vetor de entrada) é aplicado aos nós sensoriais da rede e seu efeito se propaga através da rede, camada por camada. Dessa forma, um conjunto de saídas é produzido como resposta real da rede. Durante o passo de propagação, os pesos sinápticos são mantidos fixos. Entretanto, durante o passo para trás, os pesos sinápticos são variados de acordo com uma regra de correção de erro. A resposta real é subtraída de uma resposta desejada (alvo) para produzir um sinal de erro. Este sinal de erro é então propagado para trás através da rede, contra a direção das conexões sinápticas.

3 METODOLOGIA

O objetivo deste capítulo é descrever a metodologia utilizada para o tratamento dos dados e para a escolha da melhor arquitetura.

3.1 METODOLOGIA APLICADA


Para a realização das simulações das previsões de vazões dos reservatórios de Sobradinho e Furnas, utilizou-se o MATLAB (*Matrix Laboratory*). O software, desenvolvido pela *The Math Works, Inc*, possui grande variedade de ferramentas (*toolboxes*) para aplicações como, por exemplo, redes neurais, lógica fuzzy, processamento de sinais e otimização de sistemas.

A *toolbox* usada neste trabalho foi a de redes neurais através da interface gráfica *NNTool*.

3.1.1 Tratamento dos Dados


A base de dados utilizada é baseada nos históricos de vazões mensais no período de 1931 a 2016 das usinas de Sobradinho e Furnas fornecidos pelo ONS (Operador Nacional do Sistema Elétrico) que estão detalhados nos apêndices deste trabalho. Os dados dos anos 2017, 2018 e 2019 foram utilizados para a realização dos testes. Esboçou-se os gráficos em função dos meses do ano a fim de comprar os valores utilizados nos testes e a média histórica de cada reservatório, mostrados no Gráfico 2 e no Gráfico 3.

Gráfico 2 - Histórico de vazões médias de Sobradinho



Fonte: A autora (2021)

Gráfico 3 - Histórico de vazões médias de Furnas



Fonte: A autora (2021)

3.1.2 Normalização dos Dados

É necessário realizar a normalização por variáveis, pois as magnitudes das variáveis de entrada das redes são distintas, conforme a Equação 3.

$$x_{(0,1-0,9)}^{norm} = \frac{x - 0,9x_{min}}{1,1x_{max} - 0,9x_{min}} \quad (3)$$

A escolha da normalização entre 0,1 e 0,9 foi para evitar que os neurônios das redes saturassem, dificultando o aprendizado durante os treinamentos (HAYKIN, 2001).

Após os resultados obtidos é necessário realizar a desnormalização dos dados, ou seja, o processo inverso.

3.1.3 Separação dos Dados para Treinamento e Validação

Como as redes neurais são projetadas para generalizar o conhecimento adquirido durante o treinamento, é necessário dividir a base de dados da seguinte forma: treinamento, validação e teste. Optou-se por 50% dos dados serem compostos para formar o conjunto de treinamento, 25% para o conjunto de validação e 25% para formar o conjunto de teste.

O conjunto de treinamento possui a maior parte dos dados, porque os pesos sinápticos são ajustados a partir deste conjunto com o objetivo de transmitir o conhecimento para as redes neurais. O conjunto de validação é utilizado para verificar a capacidade de generalização da rede durante o treinamento, portanto, é usado como critério de parada de treinamento para que os dados de treinamento não sejam memorizados. Já o conjunto de teste tem como função estimar o desempenho das redes quando elas estiverem em operação.

3.2 EXPERIMENTOS PARA ESCOLHA DA REDE NEURAL

Com o objetivo de evitar a memorização dos dados de treinamento pela rede neural e assim limitar a sua capacidade de generalização, as arquiteturas são definidas de acordo com a variação do número de neurônios na camada intermediária, sendo selecionada a que apresentar o menor erro médio quadrático (MSE) durante os treinamentos.

A inicialização dos pesos sinápticos é realizada de modo aleatório, pois, assim como a arquitetura, pode influenciar na performance dos treinamentos. Dessa forma, os pesos sinápticos são inicializados dez vezes para garantir que a seleção da melhor arquitetura não tenha sido influenciada por uma inicialização ótima de pesos.

3.2.1 Análise de Desempenho

O erro médio quadrático (MSE) dos conjuntos de treinamento e validação foi calculado conforme a Equação 4.

$$MSE = \frac{L_{m\acute{a}x} - L_{m\acute{i}n}}{N \cdot P} \sum_{p=1}^P \sum_{i=1}^N (L_{pi} - T_{pi})^2 \quad (4)$$

O cálculo da porcentagem do erro médio absoluto (MAPE), Equação 5, permite a avaliação dos resultados das simulações das redes neurais, pois mostra o desvio médio entre os valores observados e os valores preditos.

$$MAPE(\%) = \frac{1}{N \cdot P} \sum_{p=1}^P \sum_{i=1}^N \frac{|L_{pi} - T_{pi}|}{T_{pi}} \times 100 \quad (5)$$

Onde:

- $L_{m\acute{a}x}$ corresponde ao valor máximo do coeficiente de saída;
- $L_{m\acute{i}n}$ corresponde ao valor mínimo do coeficiente de saída;
- N é o número de unidades de saída da rede neural;
- P é o número de padrões da base de dados;
- L_{pi} é a saída calculada por cada unidade de saída da rede;
- T_{pi} é a saída almejada da rede para cada unidade.

O erro médio quadrático dá um peso maior para os desvios grandes, uma vez que são elevados ao quadrado, enquanto o erro médio absoluto dá um peso igual a todos os desvios.

3.2.2 Critérios de Parada dos Treinamentos

Os critérios de parada adotados neste trabalho foram os seguintes:

1. Número de épocas: estipulou-se o número máximo de 10000 épocas. As épocas correspondem ao número de vezes que o conjunto de treinamento é passado na rede neural.

2. Early Stop: utiliza-se esse critério para que a capacidade de generalização das redes neurais aumente através do erro no conjunto de validação. Quando o erro deste conjunto aumenta em um determinado número de épocas, o treinamento é interrompido e os pesos sinápticos e bias são retornados aos seus valores do momento de menor erro sobre o conjunto de validação.
3. Desempenho mínimo de treinamento: o treinamento é interrompido utilizando este critério quando o erro médio quadrado for igual a zero.

Quando qualquer um dos critérios citados acima for atingido, o treinamento da rede é interrompido.

3.3 SELEÇÃO DA REDE NEURAL

Adotou-se o critério de treinar várias redes neurais modificando os números de neurônios na camada intermediária na rede neural variando de 5 a 10. A rede a ser selecionada é a que obtiver menor MSE durante os treinamentos sobre o conjunto de validação.

Para cada número de neurônios, os treinamentos das redes são inicializados dez vezes com pesos aleatórios. No final de cada conjunto de dez inicializações, o erro médio quadrático é anotado. Assim, o conjunto que apresentar menor erro será o selecionado, e então, avalia-se o erro das dez inicializações e escolhe-se a melhor rede.

4 MODELO DE PREVISÃO

Esse capítulo aborda o modelo de rede neural utilizado para a análise das previsões de vazão.

4.1 HORIZONTES PARA PREVISÃO DE VAZÃO

Os horizontes para previsão de vazão podem ser classificados da seguinte forma:


- Previsão de vazão de curto prazo: são realizadas estimativas de vazões médias diárias para um horizonte de até 14 dias à frente, tomando como base o histórico de vazões médias semanais ou diárias;
- Previsão de vazão de médio prazo: são realizadas estimativas de vazões naturais médias mensais com horizonte de um mês, por meio do histórico de vazões naturais médias mensais e usando modelagem estocástica;
- Previsão de longo prazo: são realizadas estimativas de vazões médias mensais para os meses seguintes com horizonte de até um ano, a partir de histórico de vazões naturais médias mensais e de distintas modelagens.

4.2 CONFIGURAÇÃO PARA PREVISÃO UTILIZANDO RNA

A configuração utilizada neste trabalho prevê um mês com horizonte de um ano. Dessa forma, tem-se como entrada a vazão do mês e obtém-se como saída a vazão do mesmo mês no ano seguinte.

Para alcançar esse objetivo, é preciso utilizar a sazonalidade. Dessa forma, as representações dos meses em senos e cossenos também foram utilizadas como entrada do sistema. A Figura 8 mostra a representação dos elementos dessa configuração.

Figura 8 - Elementos da configuração utilizando cossenos e senos



Fonte: Tavares (2009)

As funções seno e cosseno são representadas na camada de entrada como dois neurônios e têm seus valores determinados pelas Equações 6 e 7.

$$\text{Neurônio 1} = \text{sen} \left(2 \cdot \pi \cdot \frac{N}{T} \right) \quad (6)$$

$$\text{Neurônio 2} = \text{cos} \left(2 \cdot \pi \cdot \frac{N}{T} \right) \quad (7)$$

Onde:

- N varia de 1 (janeiro) a 12 (dezembro);
- T corresponde ao período. Nesse caso, T=12.

A configuração utilizada neste trabalho correspondeu à configuração um mês à frente e utiliza os três meses anteriores e consecutivos ao que se deseja prever. O Quadro 1 mostra essa representação.

Quadro 1 - Configuração um mês à frente utilizada para treinamento da rede

Entrada 1	Entrada 2	Entrada 3	Saída
Outubro	Novembro	Dezembro	Janeiro
Novembro	Dezembro	Janeiro	Fevereiro
Dezembro	Janeiro	Fevereiro	Março
Janeiro	Fevereiro	Março	Abril
Fevereiro	Março	Abril	Maio
Março	Abril	Maio	Junho
Abril	Maio	Junho	Julho
Maio	Junho	Julho	Agosto
Junho	Julho	Agosto	Setembro
Julho	Agosto	Setembro	Outubro
Agosto	Setembro	Outubro	Novembro
Setembro	Outubro	Novembro	Dezembro

Fonte: A autora (2021)

5 RESULTADOS

Este capítulo mostra os resultados das previsões de vazão na bacia do rio São Francisco no posto de Sobradinho e na bacia do Rio Grande no posto de Furnas e as conclusões obtidas.

5.1 RESULTADOS DAS VALIDAÇÕES DE TREINAMENTO

A Tabela 1 mostra o erro médio quadrático (MSE) obtido em cada treinamento do posto de Sobradinho e a Tabela 2 refere-se ao MSE dos treinamentos do reservatório de Furnas.

Tabela 1 - Erros obtidos na validação de Sobradinho

Iteração	MSE					
	10 neurônios	9 neurônios	8 neurônios	7 neurônios	6 neurônios	5 neurônios
1 ^a	0,002853	0,002858	0,002754	0,002225	0,004152	0,005678
2 ^a	0,003898	0,002909	0,002303	0,003323	0,002805	0,003250
3 ^a	0,002585	0,002962	0,002449	0,004572	0,003083	0,002916
4 ^a	0,002283	0,002894	0,004082	0,005573	0,002436	0,002893
5 ^a	0,003948	0,003087	0,002351	0,004233	0,003781	0,004414
6 ^a	0,002312	0,003341	0,030495	0,003595	0,003361	0,003404
7 ^a	0,003904	0,001941	0,003328	0,004840	0,002946	0,002638
8 ^a	0,004064	0,004156	0,002920	0,002442	0,002928	0,005400
9 ^a	0,003758	0,003203	0,002971	0,002793	0,003902	0,003818
10 ^a	0,002729	0,002514	0,003870	0,001772	0,003368	0,002808
Média	0,003233	0,002986	0,005752	0,003537	0,003276	0,003722

Fonte: A autora (2021)

Tabela 2 - Erros obtidos na validação de Furnas

Iteração	MSE					
	10 neurônios	9 neurônios	8 neurônios	7 neurônios	6 neurônios	5 neurônios
1 ^a	0,005336	0,007234	0,007851	0,006508	0,006315	0,005179
2 ^a	0,007914	0,005241	0,007184	0,004432	0,006411	0,009010
3 ^a	0,005146	0,005717	0,005803	0,004973	0,006260	0,009758
4 ^a	0,007243	0,005146	0,007209	0,005679	0,005596	0,004554
5 ^a	0,010265	0,006666	0,007179	0,006248	0,007391	0,007638
6 ^a	0,006738	0,006686	0,008351	0,005112	0,007855	0,006136
7 ^a	0,005745	0,004805	0,007459	0,005388	0,005152	0,005499
8 ^a	0,005815	0,006808	0,007106	0,005843	0,006408	0,005929
9 ^a	0,005573	0,006221	0,004508	0,006287	0,004780	0,004961
10 ^a	0,009301	0,010303	0,005465	0,006787	0,007243	0,007359
Média	0,006907	0,006483	0,006812	0,005726	0,006341	0,006602


Fonte: A autora (2021)

Analisando as tabelas acima, verifica-se que a melhor rede neural para Sobradinho correspondeu ao modelo com 9 neurônios na camada oculta na sétima iteração, ou seja, após inicializar os pesos sinápticos sete vezes. Para o posto de Furnas, a melhor arquitetura foi com 7 neurônios na camada oculta durante a segunda iteração.

5.2 RESULTADOS DAS PREVISÕES

O resultado da simulação para o reservatório de Sobradinho para os anos 2017, 2018 e 2019 forneceu um MAPE de 94,34%, 43,84% e 55,76%, respectivamente, mostrado no Gráfico 4.


Gráfico 4 - Erro da previsão de Sobradinho para os anos 2017,2018 e 2019



Fonte: A autora (2021)

No Gráfico 5 são apresentadas a vazão média mensal para o período de 1931 até 2016, a vazão média mensal de 2009 até 2016 e a vazão média mensal prevista pelo modelo dos anos de 2017, 2018 e 2019 de Sobradinho.


Gráfico 5 - Vazões reais e previstas de Sobradinho



Fonte: A autora (2021)

A simulação para o reservatório de Furnas apresentou MAPE para os anos de 2017, 2018 e 2019, mostrados no Gráfico 6, de 38,25%, 31,1% e 30,96%, respectivamente.


Gráfico 6 - Erro da previsão de Furnas para os anos 2017,2018 e 2019



Fonte: A autora (2021)

O Gráfico 7 mostra a vazão média mensal para o período de 1931 até 2016, a vazão média mensal de 2009 até 2016 e a vazão média mensal prevista pelo modelo dos anos de 2017, 2018 e 2019 de Furnas.

Gráfico 7 - Vazões reais e previstas de Furnas



Fonte: A autora (2021)

6 CONCLUSÕES

Nota-se que o comportamento das vazões reais mais recentes diverge significativamente da média da base de dados utilizada (1931-2016). Essa diferença é ainda mais notável quando se analisa o posto de Sobradinho, que na previsão de 2017 apresentou um erro médio de 94,34%.

A previsão mensal para Furnas, no período 2017 a 2019, resultou em um erro de 33,44%, e para Sobradinho, no mesmo intervalo, o erro foi de 64,65%.

Dessa forma, as séries históricas de vazões são fundamentais para análise e tomada de decisão do atendimento adequado da demanda energética no Brasil. Através desses dados é possível realizar as previsões de vazão dos reservatórios.

Nesse sentido, o uso de redes neurais artificiais para a previsão de vazão mostra bom desempenho e contribui para um planejamento mais eficiente do sistema hidroelétrico do país.

6.1 TRABALHOS FUTUROS

A análise realizada neste trabalho tomou como base um único modelo de rede neural artificial para avaliar sua aplicabilidade na previsão de vazão. Desse modo, a técnica de validação cruzada *k-fold* pode contribuir para avaliar a capacidade de generalização do modelo com a base de dados, mitigando assim as divergências entre os dados históricos de vazão e os valores das vazões mais recentes.

Essa técnica consiste em dividir a base de dados em *k* subconjuntos distintos de mesmo tamanho e utilizá-los para treinamento da rede. Ao final de cada treinamento, o erro médio absoluto percentual (MAPE) é calculado, obtendo então uma medida mais confiável do modelo.

Outras possibilidades são:

- Ampliar o uso de modelos de RNA;
- Propor novos modelos utilizando inteligência artificial;
- Realizar previsões para outros horizontes;
- Utilizar outras ferramentas e algoritmos.

REFERÊNCIAS

BALLINI, R. S. **Redes Neurais Nebulosas para Previsão de Vazões Mensais**, 2001.

BRAVO, J. M. Previsões de Curto Prazo de Vazão Afluente ao Reservatório de Furnas Utilizando Redes Neurais Artificiais. **Revista Brasileira de Recursos Hídricos**, v. 13, 2008.

FINEP. **Previsão de afluência a reservatórios hidrelétricos** - módulo 1, 2007.

HAYKIN, S. **Redes neurais: princípios e prática**. 2ª ed. Porto Alegre, RS: Bookman, 2001.

LIMA, C. H. Análise e Previsões de Afluências ao Reservatório Sobradinho Utilizando um Modelo Periódico Autoregressivo Exógeno (Parx). **XVII Simpósio Brasileiro de Recursos Hídricos**, 2007.

ONS. **Plano de Operação Energética 2020/2024** - Sumário Executivo, 2020.

SILVEIRA, T. M. **Modelos de Previsão de Carga Elétrica em Curto Prazo Desenvolvidos com Redes Neurais Artificiais e Lógica Fuzzy Considerando a Variável Temperatura**, 2010.

TAVARES, I. A. **Previsão de Vazão Utilizando Modelos de Inteligência Artificial**, 2009.

**APÊNDICE A – SÉRIE MENSAL DE AFLUÊNCIAS DO RESERVATÓRIO DE
SOBRADINHO NO PERÍODO DE 1931-2016**

Ano	Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez
1931	4676	4805	6630	7333	4467	2397	1870	1619	1448	1376	1935	2207
1932	4036	4531	3214	1976	1425	1292	1176	995	905	982	2107	3594
1933	5014	5516	3429	2692	1905	1357	1250	1072	915	1194	1799	3336
1934	6110	4222	2298	1615	1785	1167	997	897	799	877	905	1605
1935	4519	5442	5408	4716	3740	2010	1557	1237	1055	1079	1178	2585
1936	2696	2664	4174	2764	2109	1300	1092	934	861	887	1597	2724
1937	4643	5598	4242	2888	2237	1454	1231	1036	900	920	2395	4703
1938	6307	4237	3850	2372	1613	1419	1157	1033	956	914	1538	2957
1939	5096	5897	4891	2156	1627	1258	1107	1035	936	1285	1020	1707
1940	3103	4739	5500	4297	1914	1416	1187	1055	861	926	2138	3793
1941	5004	4423	4132	4791	2721	1658	1423	1260	1022	1137	1670	2315
1942	4624	4420	5277	3360	2274	1547	1300	1117	1024	1324	2274	5170
1943	6185	9469	7966	5097	2881	2113	1774	1522	1290	1394	2205	5150
1944	6328	4864	4749	3729	2518	1738	1468	1278	1102	962	1651	3848
1945	5632	6944	7973	7150	8764	3939	2591	2078	1703	1978	3267	5593
1946	7284	10080	4595	5591	3581	2453	2009	1724	1497	1518	2171	3769
1947	3749	5142	5706	7283	4318	2353	1942	1626	1613	1436	3112	4248
1948	6343	4520	5422	4016	2210	1846	1581	1359	1207	1323	1504	5155
1949	7850	9219	13034	7136	3499	2589	2155	1820	1547	1464	2929	2944
1950	4451	4716	3461	3784	2620	1742	1515	1305	1076	1266	2138	4127
1951	4179	4156	4439	4855	2522	1846	1487	1276	1103	1027	942	1641
1952	3310	4717	5792	6938	3257	1971	1605	1312	1192	1136	1782	3393
1953	3563	1792	2684	3741	1934	1308	1108	972	858	1161	1411	3189
1954	4405	2779	2780	2429	1444	1201	979	852	715	645	880	3544
1955	2310	4051	2165	2616	1437	1072	900	788	678	661	1977	3305
1956	5370	2215	4585	2543	1773	1640	1325	1067	903	841	1468	3687
1957	5948	7119	6903	7965	5817	2769	2033	1644	1373	1522	1416	4341
1958	3623	5212	3385	3104	2421	1697	1413	1421	1128	1518	1838	1798
1959	3601	3660	3495	2708	1364	1139	1015	906	820	847	1600	2711
1960	3291	5729	6124	6060	2468	1764	1388	1151	979	902	1076	4172
1961	5755	7765	6407	3479	2328	1737	1389	1188	993	883	1098	1680
1962	3616	5406	4433	3161	2003	1476	1260	993	844	1173	1967	3057
1963	5658	6556	3462	1684	1401	1119	991	898	801	712	946	1106
1964	3543	7732	5284	2569	1566	1166	1019	924	734	878	2855	4250
1965	5188	5056	5560	5836	2872	1837	1510	1269	1053	1430	2663	4170
1966	4402	6188	6708	4287	2625	1908	1513	1330	1081	1200	1911	2532
1967	5105	4685	4016	3596	2453	1537	1296	1135	968	887	1703	3911
1968	5561	4444	6495	5090	2309	1641	1430	1307	1238	1298	1760	4453
1969	2837	3950	3851	2322	1656	1233	1107	987	841	905	2631	4879
1970	5959	6441	4717	2574	1899	1428	1273	1098	1060	1561	2982	2702
1971	1650	1436	1755	1407	1122	913	827	722	743	1182	2377	6411

1972	4959	2886	3381	2972	1785	1250	1143	1021	863	1418	1969	3790
1973	4644	3784	3607	4402	2054	1443	1253	1001	836	1341	3233	4492
1974	4561	3046	3222	5184	2872	1718	1397	1233	1046	1116	1868	2410
1975	4301	4111	2392	2446	1924	1233	1133	961	780	1033	2358	2727
1976	2007	1927	2107	1765	1037	1015	796	772	985	1442	2187	4818
1977	4701	5751	2163	2131	1797	1294	1091	955	912	1149	1477	2873
1978	5872	5145	6259	4019	2490	2221	1526	1458	1187	1614	2055	4045
1979	5929	9409	15676	7174	3610	2745	2267	1949	2034	1992	3305	3333
1980	6347	9918	10490	4684	3388	2359	2220	1875	1669	1808	2380	4856
1981	5974	4916	3817	5781	2728	2026	1637	1509	1342	1960	4448	6170
1982	6811	7990	7135	6885	3678	2536	2131	1765	1586	1618	1481	1701
1983	5072	7258	9245	6550	4189	2510	2070	1748	1441	2050	3720	5827
1984	6328	2999	2686	3469	1773	1328	1158	1059	1270	1314	1691	3888
1985	5566	7789	6701	5015	2432	1773	1423	1259	1235	1636	2148	3265
1986	6332	7556	4732	2140	1753	1283	1230	1230	1128	1056	1117	1872
1987	3150	2606	2604	2759	1701	1159	1071	840	800	920	1325	3709
1988	5163	3829	4116	2843	1852	1173	1033	979	767	989	1566	2619
1989	3601	2715	3018	1672	1142	1030	1013	858	893	996	1883	5073
1990	9467	3681	3101	1975	1359	1060	1130	987	968	984	1355	1617
1991	3742	5138	4639	5139	2340	1470	1222	1125	1031	1323	2095	3057
1992	4651	9244	12915	3754	2614	1765	1444	1283	1384	1860	4269	4814
1993	5840	4644	3943	2590	1801	1439	1245	1105	981	1214	1180	2046
1994	5366	4689	4993	4521	2154	1470	1378	1081	1022	782	989	3062
1995	2872	3220	2837	2587	1731	1188	1087	851	672	895	1651	3244
1996	4478	2180	2234	1593	1184	934	785	668	699	730	1702	3317
1997	6202	4622	4461	4053	2438	1747	1294	1197	1047	1052	1343	3446
1998	3343	3360	3096	1536	1122	950	838	751	620	704	1994	3241
1999	3013	1827	4212	2245	1201	874	787	663	695	570	1601	2990
2000	4169	5271	4455	3316	1730	1188	930	923	918	703	1823	3655
2001	3158	1695	1719	1096	845	824	645	632	659	714	1201	2187
2002	4440	4761	3516	2234	1074	883	851	644	506	665	936	1871
2003	4118	4387	2737	2604	1374	983	890	747	680	506	843	1611
2004	3233	5002	6786	5329	2737	1493	1304	1010	899	889	1063	1841
2005	4123	4915	4807	4044	2133	1463	1185	975	984	923	1402	4442
2006	4388	2412	3631	4132	2229	1297	1072	1022	976	1382	2696	4062
2007	5905	6947	6765	2547	1482	1302	995	996	727	573	614	1588
2008	1933	4021	4465	3964	1901	1127	928	843	669	729	945	2303
2009	5409	5072	3542	4254	2410	1492	1236	976	1019	1393	2534	2730
2010	3459	1939	2642	2701	1289	1025	815	690	683	831	1794	3086
2011	4656	2947	4010	5080	1881	1232	1036	804	737	973	1272	3635
2012	5948	5205	2120	2114	1251	1221	904	755	653	554	1559	2143
2013	1662	3586	1762	2857	1383	1127	843	755	605	671	903	2842
2014	3420	1280	1304	1738	1009	695	767	679	634	427	770	2210
2015	1133	1558	1894	2172	1360	789	630	518	406	227	307	1078
2016	2035	4424	1583	835	516	470	382	386	313	354	704	1989

**APÊNDICE B – SÉRIE MENSAL DE AFLUÊNCIAS DO RESERVATÓRIO DE
FURNAS NO PERÍODO DE 1931-2016**

Ano	Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez
1931	1476	2964	2167	1585	1254	785	607	469	538	662	667	1127
1932	1908	1898	1534	868	673	632	473	393	388	521	573	1474
1933	1330	726	696	610	441	356	329	325	295	411	295	692
1934	1210	699	752	480	333	276	240	204	247	272	320	1285
1935	1846	2584	1547	1334	909	674	554	468	436	619	527	661
1936	594	662	1812	942	626	436	365	352	445	351	601	1302
1937	2600	1589	1112	832	836	620	456	364	307	819	997	2343
1938	1899	1646	1445	952	850	637	508	481	481	793	914	1647
1939	2089	1999	1063	957	728	559	483	398	351	398	606	1356
1940	2018	2425	2077	1144	824	637	513	408	382	464	1043	1554
1941	1710	1005	973	794	508	458	456	334	607	666	704	1307
1942	1309	1244	1863	1033	768	637	546	419	390	540	858	1231
1943	2727	2198	2057	1132	826	680	554	495	442	648	657	1094
1944	1003	1521	1631	915	618	495	422	347	293	340	508	671
1945	875	1978	1208	995	628	553	500	349	314	349	765	1585
1946	3201	1310	1467	1152	756	627	548	430	335	516	690	749
1947	1775	1840	3757	1677	1034	804	699	548	814	627	714	1331
1948	1503	1721	1826	1075	769	668	480	419	349	385	765	1263
1949	1682	2221	1327	951	757	618	467	385	337	399	716	1153
1950	1559	2519	1581	1185	852	655	592	496	428	485	1059	1649
1951	1568	1994	1806	1276	899	700	557	476	388	432	377	761
1952	1214	1881	2356	1386	770	706	507	406	404	382	661	791
1953	605	680	839	1040	509	409	354	303	307	330	513	813
1954	743	1261	666	661	632	450	328	273	222	299	420	593
1955	1186	722	913	665	417	380	280	232	248	284	417	1163
1956	1103	712	1184	597	564	532	399	430	352	310	416	1165
1957	1605	1475	1663	1548	952	681	587	465	620	437	784	1202
1958	955	1535	1249	897	894	752	638	480	585	662	711	847
1959	1815	1408	1250	1094	693	581	497	465	401	428	668	780
1960	1564	1646	2119	999	859	651	638	508	397	428	548	1311
1961	2747	2902	2754	1457	1223	841	676	571	506	426	636	772
1962	1300	2389	1573	944	796	696	534	472	464	695	833	1454
1963	1723	1489	994	640	524	442	399	347	297	369	507	334
1964	1453	1954	823	752	611	469	378	258	225	531	742	1255
1965	2464	3125	2523	1321	1438	1062	947	777	641	973	1188	1869
1966	3033	2092	2679	1450	1034	726	581	486	484	805	1343	1856
1967	3014	2594	1916	1168	880	763	624	546	503	523	1080	1303
1968	1656	988	959	612	471	409	358	367	363	453	390	1337
1969	1171	1193	966	636	413	436	338	313	214	478	1241	1143
1970	1412	1280	1321	761	534	446	430	347	614	527	827	555
1971	612	357	477	401	310	365	309	218	232	470	533	1546

1972	1319	1776	1623	892	596	469	618	442	384	694	1132	1290
1973	1587	1428	920	1133	662	502	438	380	333	486	739	1409
1974	1830	1064	1544	1118	673	661	512	405	314	411	394	1095
1975	1460	1555	871	704	502	380	414	261	241	456	987	1196
1976	958	1143	1266	962	775	753	784	744	1068	917	1373	1915
1977	1986	1616	1193	1189	698	596	467	363	583	420	832	1449
1978	1919	1268	1224	756	707	699	495	372	354	494	892	1100
1979	1385	2413	1422	963	808	642	578	552	733	527	946	1651
1980	2690	1929	1121	1709	915	784	674	487	492	459	824	1762
1981	2713	1297	1216	917	698	704	504	469	355	819	1325	2333
1982	2417	1820	2845	1651	1061	952	760	627	488	769	798	2073
1983	3506	3230	3046	2327	1572	2303	1308	921	1889	1822	1989	3123
1984	2192	1315	994	914	861	577	466	482	547	424	631	1326
1985	2594	2210	2434	1343	881	680	565	476	503	470	759	1036
1986	1716	1540	1365	806	833	555	565	590	369	294	343	1700
1987	1945	1757	1209	1232	838	703	548	434	573	459	590	1345
1988	1303	1788	1421	843	713	645	435	384	321	563	655	810
1989	1795	1580	1619	893	596	553	487	476	487	437	512	1128
1990	1364	639	1086	723	630	428	432	405	462	443	384	591
1991	1926	1981	1764	1915	1032	677	579	425	390	666	458	809
1992	2875	2406	1408	1052	1003	614	597	448	695	796	1298	1188
1993	1301	1938	1512	1103	717	727	502	435	457	566	437	705
1994	1927	845	1224	775	868	563	458	352	273	306	460	1062
1995	924	2788	1193	998	741	532	471	311	273	637	617	988
1996	1928	1231	1431	829	664	499	442	389	681	518	1455	1736
1997	3621	1824	1498	1066	765	863	578	437	405	502	715	1185
1998	1191	1248	965	676	571	513	362	360	260	501	525	1010
1999	1681	1410	1545	754	531	502	400	278	290	210	335	796
2000	2248	1817	1376	811	540	493	419	380	558	302	703	1013
2001	896	713	628	494	374	294	250	217	272	400	567	1029
2002	1240	1982	1147	641	512	420	381	308	354	222	549	998
2003	1882	1396	1072	718	531	394	385	271	261	302	433	916
2004	1252	1614	1326	1048	761	692	564	386	294	483	520	1526
2005	2239	1713	1541	874	950	676	561	416	477	392	721	1352
2006	1114	1161	1377	673	495	425	362	283	325	472	671	1268
2007	3364	2146	948	746	601	527	463	354	241	294	647	880
2008	1092	1737	1758	1448	771	624	460	433	418	477	866	1558
2009	2028	2485	1619	1643	843	696	630	525	705	828	658	1813
2010	1811	1026	1268	807	579	478	426	301	284	455	861	1512
2011	2959	1087	1931	1063	698	628	488	388	298	459	515	1648
2012	2628	1225	910	724	675	740	508	340	262	253	435	665
2013	1814	1655	1245	996	629	648	499	363	351	505	559	980
2014	497	274	330	387	267	252	233	200	143	102	290	544
2015	308	600	806	527	388	328	256	189	401	166	526	897
2016	1650	1123	1186	581	446	637	339	284	229	365	653	650