

CENÁRIOS ALTERNATIVOS DE PRECIPITAÇÃO PARA ESTUDOS DE MUDANÇAS CLIMÁTICAS NA BACIA DO RIO PIRACICABA

Camila Billerbeck¹; Arisvaldo Vieira Mélo Junior²

RESUMO – Estudos recentes do IPCC indicam provável aumento da temperatura global nos próximos séculos. Alterações climáticas causam impactos diretos em índices pluviométricos e consequentemente, na disponibilidade hídrica. Estas informações, aliadas ao recente período de seca enfrentado por regiões brasileiras entre 2013 e 2014, mostram a necessidade de modelos e ferramentas que auxiliem análises e estudos quanto aos impactos de eventuais mudanças nos regimes de precipitação em sistemas de recursos hídricos. O presente trabalho propõe uma metodologia para geração de cenários alternativos de precipitação mensal entre 2019 e 2099, por meio de redes neurais artificiais (RNAs), a partir dos cenários RCP4.5 e RCP8.5 das projeções climáticas do modelo climático ETA-HadGEM2-ES para regiões da bacia do rio Piracicaba. As séries alternativas de precipitação apresentaram melhores parâmetros de correlação e NSE com os dados observados entre 2006 e 2018 do que a série do modelo de projeção climática. Quanto ao período futuro (2019 a 2099) as séries alternativas apresentaram variações no comportamento precipitações médias mensais se comparadas às precipitações do modelo de projeção climática. Os cenários resultantes obtidos pelas RNAs apresentam-se como alternativas para estudos e análises de impactos de mudanças climáticas em sistemas de recursos hídricos.

ABSTRACT – Recent IPCC reports indicate increases in global temperatures over the next centuries. Climate change causes direct impacts on rainfall and water availability. This information, together with the recent drought in Brazilian regions between 2013 and 2014, reveals the importance of modelling techniques and tools to support analysis and studies on the impacts of eventual changes in precipitation regimes in water resources systems. The present paper aims to propose an approach for the generation of alternative monthly rainfall scenarios from 2019 to 2099, through artificial neural networks (ANNs), from the RCP4.5 and RCP8.5 scenarios of climate change projection derived from ETA-HadGEM2- ES model, for regions of Piracicaba river basin. The alternative rainfall scenarios presented better correlation and NSE parameters with the observed data between 2006 and 2018 than the climate projection model. For the future period (2019 to 2099), the alternative rainfall scenario presented variations of average rainfall when compared to the climate projection model. The resulting ANN rainfall scenarios are considered good alternatives for studies and analyses of impacts of climate change on water resources systems.

Palavras-Chave – Cenários de precipitação, Redes Neurais Artificiais, ETA-HadGEM2- ES.

1. INTRODUÇÃO E OBJETIVOS

A questão das mudanças climáticas ganhou destaque com a primeira publicação dos estudos do IPCC (Painel Intergovernamental sobre Mudanças Climáticas) na década de 90. Os estudos mais recentes do IPCC no AR5 (IPCC, 2014) indicam um provável aumento das temperaturas do planeta ao longo dos próximos séculos. Estas alterações climáticas impõem uma série de desafios sobre

1) LabSid-PHA-Escola Politécnica (USP): camila@labsid.eng.br / camila.billerbeck@usp.br

2) LabSid-PHA-Escola Politécnica (USP): arisvaldo@usp.br

diversos setores da sociedade e de bem-estar social. Além disso, seus impactos afetam diretamente os regimes hidrológicos, e conseqüentemente, a disponibilidade hídrica.

Entre os anos de 2013 e 2014, as regiões sudeste e do semiárido brasileiro sofreram grandes impactos devido ao baixo regime de precipitação, causando dificuldades no abastecimento de água. Eventos como este, aliados às perspectivas de alterações em cenários de precipitação decorrentes de mudanças climáticas, refletem a necessidade de modelos que viabilizem análises de impactos de mudanças climáticas em sistemas de recursos hídricos.

O objetivo do presente trabalho é obter cenários alternativos de precipitação mensal entre 2019 e 2099, por meio de redes neurais artificiais, a partir dos cenários RCP4.5 e RCP8.5 das projeções climáticas do modelo ETA-HadGEM2-ES, disponíveis na Plataforma PROJETA (Chou et al., 2014a; Chou et al., 2014b; Lyra et al., 2017), para locais selecionados na bacia do rio Piracicaba.

2. REVIÃO BIBLIOGRÁFICA

Os itens a seguir apresentam uma breve revisão bibliográfica sobre os conceitos pertinentes adotados no trabalho.

2.1. Mudanças Climáticas

Segundo o AR5 (IPCC, 2014), o aumento das temperaturas globais está relacionado aos níveis de gases de efeito estufa na atmosfera. Os estudos indicam tendências de maiores ocorrências de eventos extremos como secas e inundações, alteração nos níveis dos oceanos e nos padrões pluviiais, e conseqüentemente impactos nos regimes hidrológicos (IPCC e 2014).

Para realizar projeções climáticas, é necessário especificar as condições que poderiam afetar os níveis de emissão dos gases de efeito estufa, que são descritas por cenários. No AR5 os cenários elaborados foram os RCPs (*Representative Concentration Pathways*) que descrevem quatro possibilidades (RCP2.6, RCP4.5, RCP6 e RCP8.5) relacionadas às emissões de gases de efeito estufa ao longo das próximas décadas (Simonovic, 2017).

Em termos de resultados, o cenário RCP2.6 é otimista e com menores níveis de emissão de CO₂, o cenário RCP4.5 representaria o cenário desejado, em que os países consigam controlar os níveis de emissões. Entretanto, o cenário RCP8.5 é o mais provável, de acordo com a tendência das atividades humanas (Schardong, Simonovic e Garcia, 2014).

Os modelos climáticos são as principais ferramentas para projetar e analisar cenários de mudanças climáticas. Devido à resolução espacial, os modelos climáticos globais (MCGs) podem não ser adequados para representar escalas regionais. Nestes casos, é usual a utilização de técnicas de regionalização, que envolvem aplicação de condições de contorno oriundas de MCGs em modelos climáticos regionais (MCR) (Chou e Nobre, 2014).

Em particular, o modelo regional ETA, vem sendo utilizado pelo CPTEC/INPE desde 1996, e tem apresentado boa concordância com as observações climáticas disponíveis para a América do Sul.

Este modelo possui versões com resolução horizontal de 5 km para a região sudeste, e de 20 km e 40 km para a América latina (Chou, 1999; Chou e Nobre, 2014). O modelo ETA-INPE utiliza condições de contorno do modelo climático global HadGEM2-ES a partir de cenários RCP4.5 e RCP8.5. O período histórico simulado é de 1961 a 2005, enquanto as projeções climáticas estão disponíveis de 2006 a 2099 para os mesmos cenários (Lyra *et.al*, 2017).

2.2. Redes Neurais Artificiais

Redes Neurais Artificiais (RNAs) são modelos computacionais inspirados no sistema nervoso biológico, com objetivo de mimetizar o funcionamento do cérebro a partir da propagação de dados através de uma rede interconectada. As RNAs possuem inúmeras aplicações em recursos hídricos, e possuem características como o compartilhamento de informações, e capacidade de aprendizado. Estes modelos são capazes de reconhecer e mapear padrões entre dados, podendo estendê-los a outro conjunto (Govindaraju e Rao, 2000; Cancelliere *et al.*, 2002; Haykin, 2008).

As unidades fundamentais de uma RNA são os neurônios, cuja ativação ou inibição é regida pela interligação entre seus elementos e seus respectivos pesos. Os neurônios são dispostos em camadas de entrada, de saída e por camadas ocultas, onde ocorre a grande parte dos cálculos (Cancelliere *et al.*, 2002; Haykin, 2008). A qualidade da rede depende dos dados que a alimentam, portanto, a seleção adequada deste conjunto é fundamental. (Cancelliere *et al.*, 2002).

A Figura 1 mostra um esquema de uma RNA e seus elementos.




Figura 1 – Esquema de uma RNA e seus elementos.

3. METODOLOGIA

A metodologia proposta possui três etapas; (i) seleção dos postos climatológicos e pluviométricos na bacia do Rio Piracicaba, e obtenção das séries de precipitação mensal do modelo de projeção climática entre 2006 e 2099, (ii) calibração da rede neural com dados de precipitação observados entre 2006 e 2018 e (iii) geração de cenários alternativos de precipitação mensal pela RNA entre 2019 e 2099 e comparação dos resultados obtidos com os resultados do modelo de projeção climática para o mesmo período.

A Figura 2 apresenta um fluxograma das etapas propostas no presente trabalho.

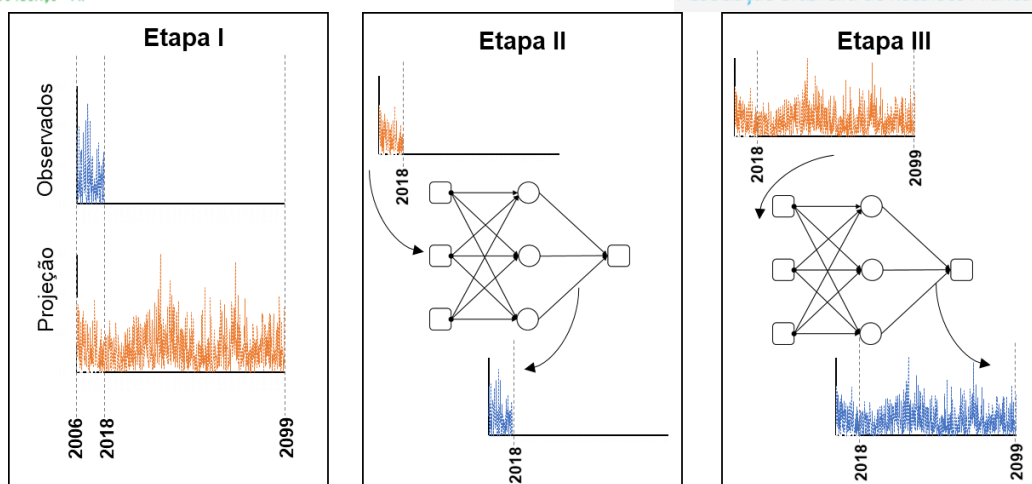


Figura 2 – Esquema da metodologia proposta.

3.1. Etapa I – Seleção e coleta dos dados disponíveis

Na etapa I foram selecionados postos climatológicos e pluviométricos em três regiões hidrologicamente semelhantes na bacia do Rio Piracicaba, com dados disponíveis de precipitação entre 2006 e 2018. A seleção dos pontos de estudo foi feita pelo critério de regiões hidrologicamente semelhantes, observando-se as isoietas de precipitação média anual (PMA) (CPRM e MME, 2011) na bacia do Rio Piracicaba.

Foram identificadas três regiões quanto ao regime pluviométrico médio anual (PMA), a Região 1 ($PMA > 1600\text{mm}$), Região 2 ($1600\text{mm} > PMA > 1400\text{mm}$), e Região 3 ($PMA < 1400\text{mm}$). Para este trabalho, três locais em cada região foram selecionados, sendo coletados dados de precipitação de postos pluviométricos e meteorológicos entre 2006 e 2018, e os resultados de precipitação projetados pelo modelo ETA-HadGEM2-ES de projeções climáticas entre 2006 e 2099, para os cenários RCP4.5 e RCP8.5. Os dados do modelo ETA-HadGEM2-ES foram gerados pelo CPTEC/INPE e estão disponíveis na Plataforma PROJETA (Chou *et al.*, 2014a; Chou *et al.*, 2014b; Lyra *et al.*, 2017).

As coordenadas utilizadas para coleta dos dados de projeção do modelo ETA-HadGEM2-ES, e características dos postos pluviométricos e climatológicos é mostrada na Tabela 1, e a localização dos mesmos é mostrada na Figura 3.

Tabela 1 – Localização e Características dos dados coletados na bacia do Piracicaba.

Região	Dados Observados				ETA-HadGEM2-ES	
	Posto	Código/Nome	Coordenadas (Lat, Long)	Intervalo	Coordenadas (Lat, Long)	Intervalo
1	Meteorológico	Monte Alegre do Sul	-22,68;-46,72	1992-2018	-22,70;-46,70	2006-2099
	Pluviométrico	2246022	-22,70;-46,670	1942-2018		
2	Meteorológico	Atibaia	-23,13;-46,55	2000-2018	-23,10;-46,55	2006-2099
	Pluviométrico	2346095	-23,10;-46,56	1938-2018		
3	Meteorológico	ESALQ	-22,70;-47,63	1917-2018	-22,70;-47,65	2006-2099
	Pluviométrico	2247094	-22,71;-47,65	1973-2015		

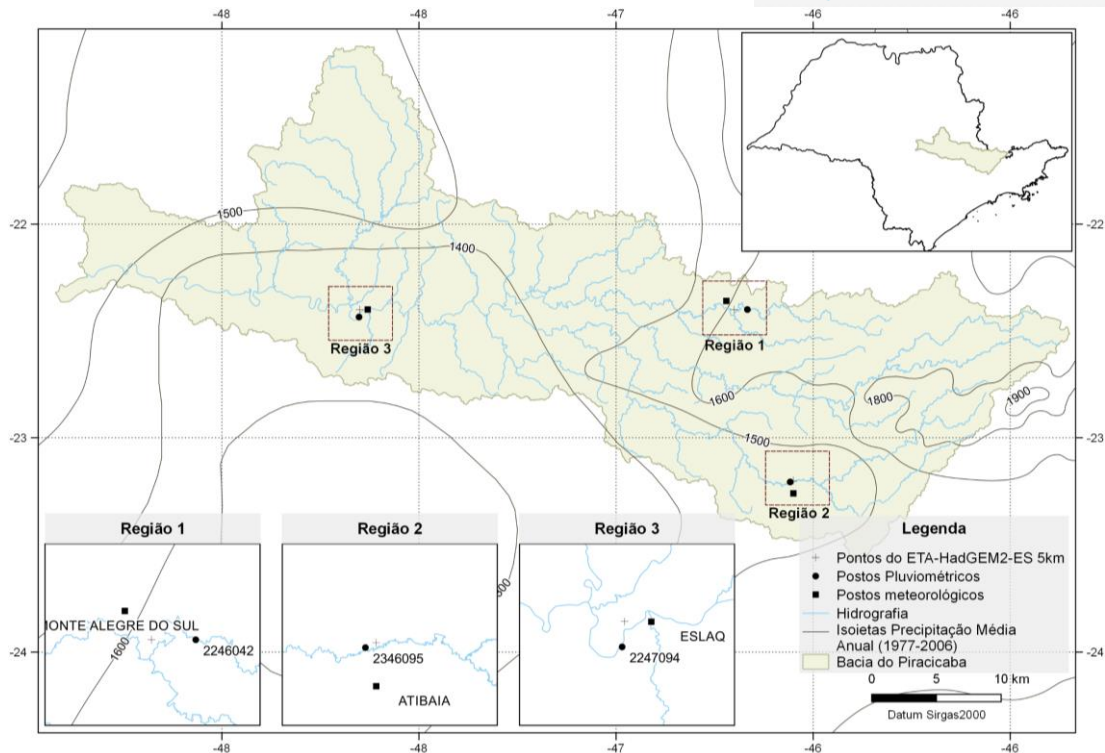


Figura 3 – Localização e Características dos dados coletados na bacia do Piracicaba.

3.2. Etapa II – Rede Neural Artificial

Na etapa II foram calibradas duas RNAs em cada região para os cenários climáticos (RCP4.5 e RCP8.5), por meio dos dados de precipitação mensal observados (2006 a 2018), a partir dos cenários projetados pelo modelo ETA-HadGEM2-ES para o mesmo período.

Esta etapa tem como premissa a hipótese de que os dados observados apresentam tendências de mudanças climáticas, sendo elas compatíveis ou não, com as tendências projetadas pelo modelo ETA-HadGEM2-ES. Uma vez calibrada, assume-se que a RNA possa gerar cenários de precipitações que incorporem o período observado nas projeções. Cabe ressaltar que este procedimento foi feito tendo em vista que os dados disponíveis do modelo ETA-HadGEM2-ES foram gerados com dados observados entre 1961 e 2005, projetando cenários de precipitação de 2006 a 2099.

Para formulação da RNA, foi utilizado o pacote *neuralnet* (Günther e Fritsch, 2010), programado em linguagem *R*, por meio da interface *RStudio*. A arquitetura da rede que obteve melhor calibração é composta por três parâmetros de entrada, três camadas ocultas com cinco, quatro e três neurônios respectivamente, e uma camada de saída, conforme mostra a Figura 4.




Figura 4 – Representação da RNA formulada.

Os parâmetros de entrada são: precipitação mensal do cenário projetado do mês i ($InputPrec$), precipitação anterior do cenário projetado $i-1$ ($InputPrecAnt$), e um parâmetro indicativo de qual o mês do ano (mês). O parâmetro de saída corresponde à precipitação mensal no mês i ($OutPrec$). Para RNAs, recomenda-se a normalização dos dados de entrada, para isso foi utilizada a Equação 1, onde X_i é a variável a ser normalizada; e X_{max} e X_{min} são os valores máximos e mínimos das variáveis:

$$Xi_N = \frac{(Xi - X_{min})}{(X_{max} - X_{min})} \quad (1)$$

A série de precipitação mensal observada possui 155 observações (de 01/2006 a 11/2018). Para a etapa de calibração da RNA selecionou-se 70% destes dados (109 observações), o restante foi analisado na etapa de validação. A seleção destes grupos foi feita previamente por um algoritmo de organização aleatória de elementos de um vetor.

O arquivo de entrada do modelo consiste em uma planilha com cinco colunas, sendo as quatro variáveis mencionadas anteriormente ($InputPrec$, $InputPrecAnt$, mês, $OutPrec$) normalizadas, e uma coluna com o contador de observações iniciando em 1 para janeiro/2006. O algoritmo lê a planilha de dados com auxílio do pacote *openxlsx*, separa as 155 primeiras observações e as ordena com base em uma ordem aleatória definida previamente, procede o cálculo da rede neural, e o replica para o restante da série gravando os resultados em um arquivo *csv*. Este procedimento foi realizado seis vezes, duas vezes por Região (conforme Tabela 1) representando os cenários RCP4.5 e RCP8.5.

Para o cálculo da rede neural, o pacote *neuralnet* permite flexibilidade para que o usuário escolha variáveis como o número de neurônios (*hidden*) na camada oculta, precisão (*threshold*), função de ativação (*act.fct*), número máximo de iterações (*stepmax*), número de repetições (*rep*), função erro (*err.fct*), aplicação ou não da função de ativação na camada de saída (*linear.output*). Os parâmetros admitidos neste trabalho podem ser vistos na Figura 5, que mostra a transcrição do algoritmo.

```
#carregar pacotes
library(neuralnet)
library(openxlsx)

#ler arquivo com dados do projeto
dados <- read.xlsx(xlsxFile="lerdados.xlsx", sheet=1,colNames=TRUE)

#ordenar os dados na ordem aleatória já definida
ordem <- read.csv("ordem.csv", header=TRUE, sep=";")
row.names(ordem) <- ordem$idobservacao
dados_random <- dados[match(row.names(ordem), row.names(dados)), 1:5]

#separa grupos de calibração e validação
calib <- dados_random[1:109, 1:5]
valid <- dados_random[110:154, 1:5]

#redeneural
rn <- neuralnet(OutPrec~InputPrec+mês+InputPrecAnt, data=calib, hidden=c(5, 4, 3),
act.fct="logistic", err.fct="sse", rep=200, stepmax=10^7, linear.output=FALSE,
threshold=0.01)

#replica a RNA calibrada com o menor erro para a série toda
proj_result <- predict(rn, dados, rep = which.min(rn$result.matrix[1,]))

#exporta o resultados
write.csv(proj_result, file="proj_result.csv")
```

Figura 5 – Algoritmo em R para o cálculo da RNA formulada.

3.3. Etapa III – Cenários Alternativos de Precipitação

Para avaliar a calibração dos modelos de rede neural no período entre 2006 e 2018 foram analisados os coeficientes de correlação (r), e o coeficiente de eficiência de Nash-Sutcliffe (NSE), mostrados respectivamente nas equações 2 e 3. O coeficiente NSE varia de $-\infty$ a 1, sendo quanto mais perto de 1, melhor a eficiência do modelo.

$$r = \frac{\sum_{i=1}^N (X_i - \bar{X}) \cdot (Y_i - \bar{Y})}{\sqrt{(\sum_{i=1}^N (X_i - \bar{X})^2) \cdot (\sum_{i=1}^N (Y_i - \bar{Y})^2)}} \quad (2)$$

$$NSE = 1 - \frac{\sum_{i=1}^N (X_i - Y_i)^2}{\sum_{i=1}^N (X_i - \bar{X})^2} \quad (3)$$

Onde \bar{X} e \bar{Y} são as médias dos respectivos conjuntos de dados, e N é o número de elementos no conjunto.

A partir das RNAs calibradas, foram obtidos cenários alternativos de precipitação mensal para os anos de 2019 a 2099. As tendências de precipitação projetadas entre 2019 e 2099 para as séries alternativas, foram comparadas às tendências dos modelos ETA-HadGEM2-ES por meio de análise de parâmetros como precipitação mensal média e precipitação total anual.

4. RESULTADOS E DISCUSSÃO

A Tabela 2 mostra os resultados de correlação (r) e coeficiente NSE referente à série observada, à série obtida com a RNA, e à série projetada pelo modelo ETA-HadGEM2-ES para período entre 2006 e 2018.

Tabela 2 – Correlação (r) e Coeficiente NSE obtidos para os conjuntos de dados observados e de projeção climática (Obs./Projeção), e entre os dados observados e obtidos pelo modelo de RNA (Obs./RNA).

Período: 2006 a 2018		Região 1		Região 2		Região 3	
Cenário	Parâmetro	Obs./Projeção	Obs./RNA	Obs./Projeção	Obs./RNA	Obs./Projeção	Obs./RNA
RCP4.5	NSE	-0,04	0,81	-0,42	0,67	-0,34	0,68
	r	0,35	0,90	0,26	0,82	0,24	0,83
RCP8.5	NSE	-0,01	0,72	-1,8	0,66	-0,62	0,76
	r	0,35	0,85	0,31	0,81	0,32	0,87

Os resultados obtidos pela RNA apresentaram melhores parâmetros com relação a série observada, do que os resultados do modelo de mudanças climáticas. Este comportamento fornece indicativos de que a série observada (2006 a 2018) não necessariamente reproduz as tendências inicialmente indicadas pelo modelo de projeção climática neste período. A Região 2 apresentou correlação e NSE menores se comparada às regiões 1 e 3, o que sugere maior divergência entre os dados de mudanças climáticas, utilizados como entrada da rede, e os dados efetivamente observados para esta região nos anos entre 2006 e 2018, utilizados para calibração.

A Tabela 3 mostra um resumo dos resultados das precipitações médias mensais comparando os cenários de precipitação observados, e os obtidos pelo modelo de projeção climática e pela RNA.

Tabela 3 – Resumo das precipitações médias mensais (mm) para os cenários de precipitação observados e projetados pelo modelo ETA-HadGEM2-ES (Projeção) e pela RNA.

Precipitações médias mensais (mm)							
Período	Cenário	Região 1		Região 2		Região 3	
		Projeção	RNA	Projeção	RNA	Projeção	RNA
2006 a 2018	RCP 4.5	119,54	123,82	123,97	101,32	117,11	104,72
	RCP 8.5	159,27	117,13	162,95	99,31	145,90	112,02
	Observado	123,26		102,76		111,15	
2019 a 2099	RCP 4.5	119,01	125,32	122,52	106,21	111,82	106,98
	RCP 8.5	104,24	123,07	105,60	103,66	96,58	110,44

Estes resultados mostram tendências média do comportamento das precipitações observadas e geradas pelo modelo de projeção climática e pela RNA. Com relação ao período observado (2006 a 2018) percebe-se que as precipitações médias observadas foram menores do que os resultados obtidos pelo modelo climático em ambos os cenários. Este comportamento reflete-se nos resultados da RNA no mesmo período. Os resultados da RNA para os cenários RCP4.5 são maiores do que os obtidos para o RCP8.5 nas regiões 1 e 2. Ao contrário dos resultados do modelo climático, em que os resultados para o cenário RSP8.5 foram maiores nas três regiões. Com relação aos cenários projetados pela RNA entre 2019 e 2099, é possível verificar nas Regiões 1 e 2, a tendência de menores precipitações no cenário RCP8.5. Este comportamento é observado no modelo de projeção climática.

Pelos resultados, percebe-se a ocorrência de variabilidade nas tendências médias no período de 2019 a 2099 para as regiões, nem sempre compatíveis com as tendências indicadas pelo modelo de projeção climática. Na Região 1, mais chuvosa, a RNA superestimou as precipitações médias com relação ao modelo de projeção climática para ambos os cenários. Contudo na Região 2, intermediária, os resultados da RNA subestimam a precipitação proveniente da projeção climática em ambos os cenários. A Região 3, de menor pluviosidade, apresentou menores precipitações para o cenário RCP4.5, e maiores para o RCP8.5, do que as médias indicadas no modelo de projeção climática.

Na Figura 6 observam-se os resultados de precipitação total anual do modelo ETA-HadGEM2-ES comparado à série alternativa gerada pela RNA para as regiões nos dois cenários. Pode-se observar que os resultados obtidos pela RNA apresentam comportamento mais homogêneo ao longo do período do que os resultados projetados com o modelo de projeção climática, os picos em geral são subestimados e os períodos de seca estão bem definidos, porém com maiores valores. A RNA tende a reproduzir o padrão de precipitações mapeado durante a etapa de calibração, portanto é provável que os cenários alternativos estejam mais compatíveis com as reais tendências de variações climáticas efetivamente observadas, do que as tendências projetadas pelo modelo climático. No entanto, é

improvável que todas as premissas admitidas no modelo ETA-HadGEM2-ES para a geração de cenários de precipitação sejam reproduzidas nos cenários alternativos por meio das RNAs.

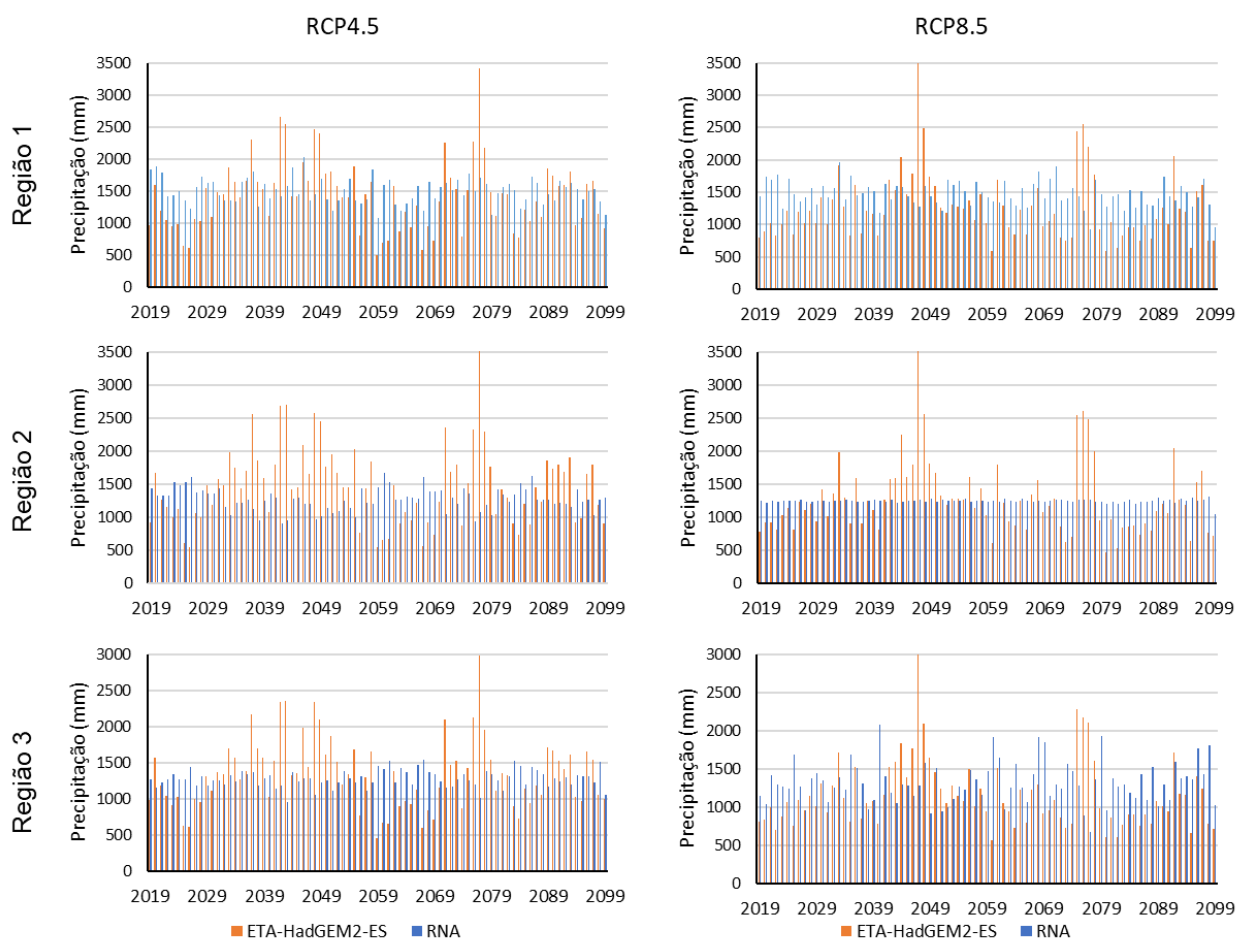


Figura 6 – Precipitações totais anuais (mm) obtidas pela RNA e pelo modelo de projeção climática.

5. CONCLUSÕES

Na aplicação apresentada neste trabalho, RNAs foram utilizadas para geração de seis cenários alternativos de precipitação tendo como entrada precipitações mensais provenientes do modelo de projeção climática ETA-HadGEM2-ES na escala de 5km para a bacia do Rio Piracicaba. As RNAs foram calibradas com dados observados entre 2006 e 2018, e obtiveram melhores ajustes de coeficientes de correlação e NSE com a série observada, do que os resultados do modelo de mudanças climáticas gerados para o mesmo período.

As séries alternativas de precipitação obtidas com as RNAs entre 2019 e 2099, apresentaram variações no comportamento de tendências médias se comparadas às precipitações obtidas pelo modelo de projeção climática. Quando comparadas, houve aumento das precipitações médias na Região 1, mais chuvosa, e diminuição na Região 2, intermediária, em ambos os cenários. Na Região

3, de menores precipitações, a RNA apresentou menores precipitações para o cenário RCP4.5, e maiores para o RCP8.5, do que as tendências indicadas no modelo de projeção climática.

Não é possível garantir que as premissas admitidas no modelo ETA-HadGEM2-ES para a geração dos cenários de precipitação estão representadas nas séries geradas pelas RNAs. No entanto, a metodologia proposta apresentou uma abordagem válida para a geração de cenários alternativos de precipitação, para estudos e modelos hidrológicos a fim de se analisar os impactos de mudanças climáticas em sistemas de recursos hídricos.

REFERÊNCIAS

- BRASIL, MCTIC, SEPED. (2016). *Third National Communication of Brazil to the United Nations Framework Convention on Climate Change*. Brasília. 2016.
- CANCELLIERE, A. *et al.* (2002). “A Neural Networks Approach for Deriving Irrigation Reservoir Operating Rules”. *Water Resources Management* (16-1), pp. 71-88.
- CHOU, S.C. (1999). *Modelo regional ETA*. Disponível em: <<http://climanalise.cptec.inpe.br/~rclimanl/boletim/cliesp10a/27.html>> Acesso em 09/01/2019.
- CHOU, S.C.; NOBRE, P. (2014) “Avaliação de modelos globais e regionais climáticos” in *PBMC, 2014: Base científica das mudanças climáticas. Contribuição do Grupo de Trabalho 1 do Painel Brasileiro de Mudanças Climáticas ao Primeiro Relatório da Avaliação Nacional sobre Mudanças Climáticas*. Org. por Ambrizzi, T., Araujo, M. COPPE, Rio de Janeiro.
- CHOU, S.C. *et al.* (2014a) “Evaluation of the Eta Simulations Nested in Three Global Climate Models”. *American Journal of Climate Change*. (3-5), pp. 438-454.
- CHOU, S.C. *et al.* (2014b). “Assessment of Climate Change over South America under RCP 4.5 and 8.5 Downscaling Scenarios”. *American Journal of Climate Change*. (3-5), pp. 512-527.
- CPRM, MME. (2011). *Levantamento da Geodiversidade - Projeto Atlas Pluviométrico do Brasil - Isoietas Anuais Médias, Período 1977 A 2006*. Disponível em <www.cprm.gov.br/publique/Hidrologia/Mapas-e-Publicacoes/Atlas-Pluviometrico-do-Brasil-1351.html> Acesso em 05/03/2019.
- GÜNTHER, F.; FRITSCH, S. (2010). “neuralnet: Training of Neural Networks”. *The R Journal*. (2-1), pp. 30-38.
- GOVINDARAJU, R.S.; RAO, A.R. (2000). “Introduction” in *Artificial Neural Networks in Hydrology*. Org por Govindaraju, R.S.; Rao, A.R. Springer Netherlands.
- HAYKIN, S.O. (2008) “*Neural Networks and learning machines*”. 3 ed. Pearson New Jersey, 936 p.
- IPCC. (2014). “Summary for Policymakers” in *Climate Change: The Physical Science Basis. Contribution of Working Group I to the Fifth Assessment Report of the Intergovernmental Panel on Climate Change*. IPCC, ed. Cambridge University Press, New York.
- LYRA, A. *et al.* (2017). “Climate change projections over three metropolitan regions in Southeast Brazil using the non-hydrostatic Eta regional climate model at 5-km resolution”. *Theoretical and Applied Climatology*. (132-1), pp. 663-682.
- SCHARDONG, A.; SIMONOVIC, S.P., GARCIA, J.I.B. (2014). “O possível efeito de mudanças climáticas e suas incertezas sobre afluências em sistemas de recursos hídricos”. *Revista de Gestão de Água da América Latina*, (11-2) pp. 53-65.
- SIMONOVIC, S.P. (2017). “Bringing Future Climatic Change into Water Resources Management Practice Today”. *Water Resources Management*, (31-10), pp. 2933-2950.