

**UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL**  
**INSTITUTO DE PESQUISAS HIDRÁULICAS**  
**PROGRAMA DE PÓS-GRADUAÇÃO EM RECURSOS HÍDRICOS E**  
**SANEAMENTO AMBIENTAL**

**ERIK SCHMITT QUEDI**

**PREVISÃO HIDROLÓGICA EM HORIZONTE SUB SAZONAL**

Porto Alegre

2019

ERIK SCHMITT QUEDI

## **PREVISÃO HIDROLÓGICA EM HORIZONTE SUB SAZONAL**

Dissertação submetida ao Programa de Pós-Graduação em Recursos Hídricos e Saneamento Ambiental da Universidade Federal do Rio Grande do Sul como requisito parcial para a obtenção do título de Mestre em Recursos Hídricos e Saneamento Ambiental.

**Orientador:** Prof. Dr. Fernando Mainardi Fan

Porto Alegre

2019

## CIP - Catalogação na Publicação

Schmitt Quedi, Erik  
PREVISÃO HIDROLÓGICA EM HORIZONTE SUB SAZONAL /  
Erik Schmitt Quedi. -- 2019.  
93 f.  
Orientador: Fernando Mainardi Fan.

Dissertação (Mestrado) -- Universidade Federal do  
Rio Grande do Sul, Instituto de Pesquisas Hidráulicas,  
Programa de Pós-Graduação em Recursos Hídricos e  
Saneamento Ambiental, Porto Alegre, BR-RS, 2019.

1. Previsão Hidrológica. 2. Previsão sub sazonal.  
3. Subseasonal-to-Seasonal. I. Mainardi Fan, Fernando,  
orient. II. Título.

ERIK SCHMITT QUEDI

## **PREVISÃO HIDROLÓGICA EM HORIZONTE SUB SAZONAL**

Dissertação submetida ao Programa de Pós-Graduação em Recursos Hídricos e Saneamento Ambiental da Universidade Federal do Rio Grande do Sul como requisito parcial para a obtenção do título de Mestre em Recursos Hídricos e Saneamento Ambiental.

Aprovado em: Porto Alegre, 26 de fevereiro de 2019.

---

Prof. Dr. Fernando Manardi Fan – IPH/UFRGS  
Orientador

---

Prof. Dr. Walter Collischonn – IPH/UFRGS  
Examinador

---

Prof. Dr. Juan Martin Bravo – IPH/UFRGS  
Examinador

---

Prof. Dr. Leonardo Calvetti – UFPEL  
Examinador

## Agradecimentos

Os agradecimentos são direcionados a todos que tiveram alguma contribuição, direta ou indireta, ao longo do desenvolvimento da pesquisa.

Ao Prof. Fernando Fan pela orientação e paciência ao longo do mestrado, em que sempre de forma brilhante e objetiva, sanou meus questionamentos sobre a pesquisa e forneceu todo apoio necessário para a continuidade da mesma.

Ao Prof. Walter Collischonn, pelas contribuições ao longo da pesquisa, pelas aulas de simulação hidrológica e momentos no grupo de pesquisa, em que, de forma simples, porem genial, foi capaz de iluminar ideias e aprendizados sobre a hidrologia.

Ao Prof. Juan Martín Bravo, por ser uma figura de muita clareza, paciência, conhecimento e humildade, que desde as aulas de Algoritmos Evolucionários, foi uma referência dentro do IPH.

Ao Prof. Leonardo Calvetti, por participar da banca e poder contribuir com seus conhecimentos na área de hidro meteorologia.

Ainda, a todos os outros professores com quem tive contato, que expresso aqui minha admiração e respeito, em especial: Prof. Guilherme Marques; Profa. Maria Lucia; Prof. André Silveira; Prof. Olavo Pedrollo; Prof. Rodrigo Paiva; Prof. Anderson Ruhoff e a Profa. Edith Schettini.

Aos colegas de grupo de pesquisa Hidrologia de Grande Escala, deixo aqui minha admiração a vocês, jovens e excepcionais pesquisadores, sejam algumas das pessoas: Ayan, Sly, Hugo, João Paulo, Otávio, Cleber, Pedro, Vinicius, Arthur, Aline, Renata, Matheus, Rafael, entre outras das quais não tive maior contato. Não obstante, àquelas pessoas de outros grupos de pesquisa, como o pessoal da Hidrologia, Tubarão, NET e demais.

À CAPES pelo apoio financeiro, e à UFRGS e ao Instituto de Pesquisas Hidráulicas, seus funcionários e à sua estrutura que fomentaram a realização deste trabalho.

Agradeço imensuravelmente à minha família. A meus pais, Nagib e Cláudia, sobretudo, pelo apoio e amor incondicional e pelo orgulho demonstrado ao longo de todo este caminho; A meus “manos”, Kim e Mark, pela parceria, amizade e confiança; A aqueles que foram meus segundo pai e mãe em Porto Alegre, Tia Chris e Tio Dunga, por me acolheram de maneira tão carinhosa, muito obrigado pela confiança e lições de valores cotidianos, além dos deliciosos almoços. Ainda, as minhas primas Maju e Clarinha, que mesmo sendo ainda jovens, ensinam muito sobre maturidade.

Por fim, à minha querida companheira ao longo desta jornada, Juliana, a qual compartilhamos e suportamos momentos difíceis e desfrutamos dos bons. Expresso aqui minha gratidão, respeito, carinho e reconhecimento do seu companheirismo, obrigado!

“O que é, pois, a verdade? ...  
... após uma longa utilização,  
parecem a um povo consolidadas,  
canônicas e obrigatórias:  
as verdades são ilusões das quais  
se esqueceu que elas assim o são...”

(Nietzsche)

Das previsões, o que é a verdade,  
senão uma referência?

(o autor)

## **Resumo**

As previsões hidrológicas feitas em horizonte sub sazonal, definido neste estudo como um prazo de antecedência máximo de 46 dias, ainda estão em fase de pesquisa científica no contexto brasileiro e sul-americano. Espera-se que essas previsões tragam benefícios para setores como energia hidrelétrica e aplicações operacionais. Neste sentido, no presente trabalho foram realizados experimentos com o objetivo de avaliar a qualidade e utilidade das previsões de precipitação sub sazonal, originadas do Centro Europeu de Previsão Meteorológica de Médio Prazo (ECMWF), na bacia do rio Paraná, uma das mais importantes bacias hidrográficas da América do Sul, em termos de geração de energia, contemplando a usina hidrelétrica binacional de Itaipu e mais de outras 150 grandes usinas hidrelétricas.

O Software Ensemble Verification System (EVS) foi aplicado para verificação estatística das previsões de precipitação sub sazonal, através de métricas determinísticas e probabilísticas, no período que vai dos anos de 2015 e 2016, utilizando os dados brutos e em um formato com viés corrigido.

Também foram realizadas simulações de previsões de vazões por conjunto, em horizonte sub sazonal, usando o modelo semi-distribuído MGB, testando os dados do ECMWF como entrada - resultando no desenvolvimento de um Sistema de Previsão Hidrológica por Conjunto (ou *Hydrologic Ensemble Prediction System*, H-EPS). As previsões de vazão foram comparadas com as simulações usando como entrada a informação climatológica, conhecida como previsão estendida de vazão (*extended streamflow prediction*, ESP).

Este estudo é uma das primeiras avaliações dos dados de previsões sub sazonais, para fins de previsão hidrológica realizados no contexto da América do Sul. A avaliação da precipitação futura permitiu a inferência do desempenho dessas previsões de precipitação para posterior utilização em modelagem hidrológica, além de quantificar alguns dos erros associados aos dados.

Os resultados apontaram que, em geral, as previsões de vazões usando os dados de previsão de precipitação sub sazonal apresentam maior previsibilidade (*skill*) do que aquelas que usam informações históricas, até aproximadamente 30 dias de previsão. A esse respeito, essas previsões podem ser exploradas particularmente em aplicações como as afluências em reservatórios, o controle de enchentes e secas e a evolução de eventos extremos várias semanas à frente.

## **Abstract**

The hydrological prediction done within sub-seasonal timescale, defined in this study as a lead-time of 46 days, is still incipient in Brazilian and South American context. It is expected that these predictions will bring benefits to sectors such as hydro-energy for scientific research and operational applications. In this sense, it is performed assessments aiming on evaluating the quality and usefulness of sub-seasonal precipitation forecasts, originated from the European Centre for Medium-Range Weather Forecast (ECMWF), in Paraná River Basin, one of the most important basins in Brazil in terms of energy generation, contemplating the bi-national Itaipú hydroelectric power plant and more than others 150 large reservoirs plants.

The Ensemble Verification System (EVS) Software was applied to perform a statistical verification of the sub-seasonal precipitation forecasts, through deterministic and probabilistic metrics on the period ranging the years of 2015 and 2016, using the raw data and in a bias corrected format.

Was also proceeded simulations of sub-seasonal streamflow forecasts using a semi-distributed hydrological model, the MGB-IPH, using the data as input - resulting in the development of an H-EPS. The streamflow forecasts were benchmarked against the simulations using as input the climatological information, or the extended streamflow prediction (ESP).

This study is one of the first evaluation of the sub-seasonal forecasts data, for hydrologic forecasting purposes, done in Brazilian context. The assessment of the future rainfall allows the inference of the performance of these precipitation forecasts for later use in hydrological modeling, also quantifies some of the errors associated with the data.

It is indicated that the streamflow predictions using the sub-seasonal precipitation forecast data presents greater predictability, or better skill, than those using historical information until approximately lead-day 30. In this regard, these forecasts may be explored particularly in applications such as reservoir inflow, flood and drought control and the onset and evolution of events several weeks ahead.

## Sumário

1.	Apresentação .....	11
1.1.	Introdução e Justificativa .....	11
1.2.	Hipóteses .....	13
1.3.	Objetivos .....	13
	Objetivo geral .....	13
	Objetivos específicos .....	13
1.4.	Organização do trabalho .....	13
2.	Revisão bibliográfica.....	14
2.1.	Previsão de variáveis hidrológicas.....	14
2.2.	Previsão a longo prazo (clima ou sazonal) .....	17
2.3.	Previsão a curto prazo (tempo) .....	17
2.4.	Horizonte sub sazonal como instrumento de previsão hidrológica .....	19
2.5.	Previsão por conjunto ( <i>ensemble</i> ).....	22
2.6.	H-EPS .....	25
2.7.	Verificação de previsões por conjunto.....	28
3.	Materiais e Métodos .....	30
3.1.	S2S .....	30
3.2.	Dados de Precipitação Observada: MSWEP v2.1 .....	32
3.3.	Modelo Hidrológico MGB-IPH.....	32
3.4.	MGB-IPH aplicado a Bacia do Rio Paraná .....	34
4.	Evaluation of Sub seasonal to Seasonal (S2S) Precipitation Forecasts for Hydrologic Forecasting Purposes Within Paraná River Basin – Brazil .....	37
4.1.	Introduction.....	38
4.2.	Materials and Methods.....	41
4.2.1.	Study Area.....	41
4.2.2.	Data .....	42
4.2.3.	Data Processing .....	43
4.2.4.	Bias Correction.....	44
4.2.5.	Verification Metrics .....	46
4.3.	Results and Discussion .....	48
4.3.1.	Accumulated Precipitation Fields .....	48
4.3.2.	Deterministic Metrics .....	50
4.3.3.	Probabilistic Metrics .....	53

4.4.	Conclusions.....	54
5.	Potential of Hydrological Sub-Seasonal Forecasts in Tropical Large-Scale Basins	56
5.1.	Introduction.....	57
5.2.	Study Catchment.....	61
5.3.	Methodology .....	63
5.3.1.	Precipitation Datasets.....	63
5.3.2.	Hydrological Model .....	63
5.3.3.	Data interpolation .....	65
5.3.4.	Ensemble Streamflow Forecast.....	65
5.3.5.	Results Assessments .....	66
5.4.	Results.....	68
5.4.1.	Individual Assessments and Spread Analysis .....	68
5.4.2.	Skill Against Reference Forecast .....	73
5.5.	Discussion.....	74
5.6.	Conclusion .....	76
6.	Conclusão .....	77
7.	Referências .....	79
8.	Anexo: Descrição do modelo meteorológico <i>ipsis litteris</i> portal S2S .....	88
1.	Ensemble version.....	89
2.	Configuration of the EPS .....	89
3.	Initial conditions and perturbations .....	90
4.	Model Uncertainties perturbations:.....	92
5.	Surface Boundary perturbations: .....	92
6.	Other details of the models: .....	92
7.	Re-forecast Configuration.....	93
8.	References:.....	93

## **1. Apresentação**

### **1.1. Introdução e Justificativa**

O conhecimento antecipado de variáveis hidrológicas como a precipitação e vazões afluentes constitui-se como informação valiosa para atender às demandas em diversos setores socioeconômicos. O processo de previsão destas variáveis pode ser feito a partir da modelagem numérica, por exemplo, as previsões quantitativas de precipitação (*Quantitative Precipitation Forecast - QPF*), que vem sendo disseminadas em aplicações científicas e sistemas operacionais (Buizza *et. al.*, 1999a; Krzysztofowicz, 2001; Bartholmes and Todini, 2005; Cuo *et. al.*, 2011; Fan *et. al.*, 2014; Fan *et. al.*, 2015c; Yuan *et. al.*, 2015; Bell *et. al.*, 2017; Greuell *et. al.*, 2018; Monhart *et. al.*, 2019).

As previsões são definidas de acordo com seu tempo máximo de antecedência futura: curto, médio e longo prazo. A QPF feita em curto prazo, com horizonte de até duas semanas, é denominada de previsão do tempo e usualmente utilizada para prever eventos individuais, como chuvas extremas e enchentes (*e.g.* Siqueira *et. al.*, 2016). A previsão de longo prazo, feita em horizonte sazonal (vários meses), é denominada de previsão do clima, na qual objetiva-se a estimativa de médias ou totais em determinado período. A precisão na qual a variável hidrológica é estimada está relacionada ao tempo máximo de antecedência da previsão, em que a qualidade ou o grau de confiança tipicamente decresce com o aumento do período de antecedência.

Atualmente, a qualidade das previsões de curto prazo, em relação as de longo prazo, apresenta uma diferença considerável. É reconhecido como “gap” (lacuna) a defasagem da capacidade (ou grau de predictabilidade) dos sistemas de previsão de longo prazo alcançarem a qualidade dos de curto prazo (NASEM, 2016).

Durante as últimas décadas foram desenvolvidas previsões de boa qualidade em curto e longo prazo, todavia, é reconhecida a carência de pesquisas em previsões que se inserem entre estes períodos, denominadas de prazo extendido ou sub sazonal.

A previsão sub sazonal é frequentemente considerada impraticável, uma vez que seu tempo máximo de antecedência é maior do que a previsão de curto prazo (natureza determinística) e menor que a de longo prazo (natureza probabilística) – isto é, o tempo de antecedência da previsão sub sazonal é longo o suficiente para que a memória das condições hidro meteorológicas iniciais sejam virtualmente perdidas, ao passo que, é

muito curto para a variabilidade de componentes do sistema terrestre que evoluem com maior inércia, tenham forte influência (White *et. al.*, 2017).

É neste contexto que desde 2015 o projeto *Subseasonal-to-Seasonal* (S2S), iniciativa das entidades WWRP/THORPEEX-WCRP, fomentam uma base de dados com previsões meteorológicas feitas em prazo sub sazonal, viabilizando pesquisas desta natureza (Vitart *et. al.*, 2017). Este projeto chegou ao fim da fase I em 2018 e apresentou nova agenda de pesquisa para os próximos cinco anos, dando início à fase II em novembro de 2018 até dezembro de 2023 (WMO, 2018). Destaca-se que, a pesquisa em previsão sub sazonal vem sendo desenvolvida há alguns anos, todavia, é reconhecido que a mesma ainda se encontra em estágios incipientes, especialmente no desenvolvimento de aplicações científicas e operacionais, e de produtos finais. Dentre alguma das questões científicas descritas na agenda de pesquisa, à luz dos recursos hídricos, abordam as principais limitações da previsão sub sazonal, atribuídas à insuficiente qualidade da previsão para atender aos usuários finais; à necessidade de um pós-processamento estatístico para calibrar a previsão, ou seja, técnicas de remoção de erros sistemáticos ou vieses; à carência em avaliações de performance das previsões em diferentes localidades; à falta de estabilidade/persistência da previsão; à dificuldade na interpretação da previsão probabilística; à falta de experiência nesta abordagem pela comunidade científica.

A grande variabilidade do estado e as incertezas das condições hidrometeorológicas, requerem a utilização de técnicas de previsão probabilística, como a previsão por conjunto ou *ensemble* (Georgakakos e Krzysztofowicz, 2001) - esta abordagem incorpora aos resultados as incertezas ou probabilidades de estados futuros. O aproveitamento deste conceito em estimativas futuras de vazão, por meio da associação de previsões meteorológicas por conjunto como dados de entrada à modelagem hidrológica, constitui um sistema de previsão hidrológica por conjunto (*Hydrologic Ensemble Prediction System*, H-EPS; Krzysztofowicz, 2001, Cloke e Pappenberger, 2009, Pappenberger e Brown, 2013).

Portanto, esta pesquisa objetivou explorar o uso de previsões quantitativas de precipitação oriundas do banco de dados *subseasonal-to-seasonal* (S2S), a partir da sua utilização na modelagem hidrológica em grande escala. Propõe-se investigações a respeito de benefícios e dificuldades na previsão hidrológica por conjunto, e particularmente em horizonte sub sazonal. Foram realizados testes estatísticos tipicamente aplicados em previsões por conjunto, fornecendo informações que ajudem a

compreender a performance (qualidade) destas previsões. Por fim, o modelo utilizado foi calibrado e validado para a Bacia do Rio Paraná, um dos mais importantes sistemas hidráulicos da América do Sul, e que, no âmbito de geração de energia hidroelétrica e navegação fluvial, é potencial beneficiária das previsões por conjunto em horizonte sub sazonal.

## **1.2. Hipóteses**

No contexto apresentado, são abordadas nesta dissertação as seguintes hipóteses:

- A previsão hidrológica em horizonte sub sazonal traz benefícios na antecipação de eventos hidrológicos, como períodos de secas e cheias, e, assim, constitui-se em uma ferramenta para sistemas de previsão.
- A previsão sub sazonal traz benefícios às atuais capacidades de previsão, relevantes à agricultura, gestão de recursos hídricos e saúde pública
- A qualidade de previsões feitas em horizonte sub sazonal apresenta vantagens em relação às técnicas que utilizam séries climatológicas.

## **1.3. Objetivos**

### **Objetivo geral**

Avaliar a qualidade e utilidade de previsões hidrometeorológicas em horizonte sub sazonal em uma grande bacia da América do Sul.

### **Objetivos específicos**

- Desenvolver e avaliar, por meio de estatísticas, um sistema de previsão hidrológica por conjunto (*H-EPS*) para a bacia do Rio Paraná;
- Verificação do acréscimo a qualidade de previsões hidrológicas sub sazonais em relação as que utilizam informações históricas;
- Avaliar a performance estatística das previsões sub sazonais de precipitação;
- Quantificar erros associados a previsão meteorológica sub sazonal.

## **1.4. Organização do trabalho**

Neste trabalho são abordados assuntos em torno da previsão de variáveis hidrometeorológicas, em específico, da precipitação e vazão. Nos capítulos 2 e 3, são apresentados a revisão bibliográfica de conceitos e as ferramentas aplicadas ao estudo.

Foram feitos dois estudos (artigos), que compõem a metodologia e os resultados deste trabalho, ambos realizados na bacia do Rio Paraná. O primeiro destes é apresentado no capítulo 4, no qual foi feito um estudo sobre os erros nos dados de precipitação, oriundos do banco de dados S2S, em relação a um referencial observado. Neste estudo, também apresenta uma investigação a respeito da correção de erros sistemáticos (viéses), na qual explorou previsões sub sazonais feitas para tempos passados (*hindcasts* ou *re-forecasts*).

No capítulo 5 está a apresentação do desenvolvimento do sistema de previsão hidrológica por conjunto (*H-EPS*), em que foram utilizadas as previsões sub sazonal de precipitação como dados de entrada do modelo MGB-IPH, obtendo estimativas de vazões como resultados. As estimativas de vazões resultantes foram avaliadas em localidades correspondentes a localização de usinas hidroelétricas, escolhidas de modo a permitir uma análise em diferentes regiões da bacia (áreas de drenagem). Também, foi feito uma avaliação estatística dos resultados, por meio de métricas comuns a verificação de previsão por conjunto e, utilizando dados históricos de precipitação, fez-se uma comparação da qualidade das previsões sub sazonais em relação aquelas geradas pela técnica *extended streamflow prediction* (ESP).

Por fim, no capítulo 6 estão descritas as conclusões do trabalho e apresentadas algumas possibilidades de trabalhos futuros na pesquisa de previsão hidrológica em horizonte sub sazonal, no contexto brasileiro e sul americano.

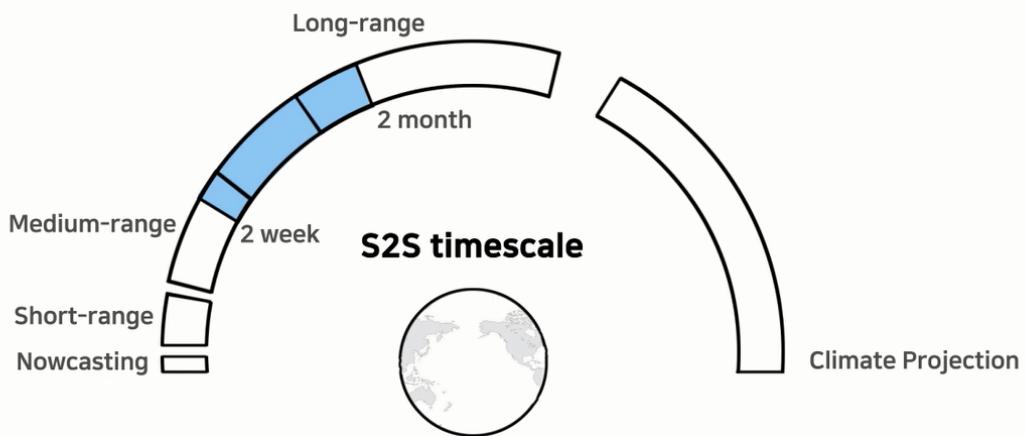
## **2. Revisão bibliográfica**

### **2.1. Previsão de variáveis hidrológicas**

As estimativas de variáveis hidrológicas, como a precipitação e vazão, para um determinado instante no futuro fornecem informações úteis e auxiliam a tomada de decisão em atividades socioeconômicas. A previsão hidrológica é definida de acordo com o tempo de antecedência máximo que esta alcança, ou horizonte da previsão. Tipicamente a acurácia (qualidade) da estimativa decresce a medida que o horizonte da previsão aumenta. Por outro lado, a utilidade da previsão cresce a medida que a antecedência da previsão é alongada (Lettenmaier e Wood, 1993).

A classificação a partir do horizonte de previsão, de horas até duas semanas é denominada a curto prazo, já aquela estimativa para períodos superiores a três meses é a longo prazo – tipicamente associa-se a primeira a previsão do tempo e a última a previsão

do clima ou sazonal (Georgakakos e Krzysztofowicz, 2001). No período entre o curto e longo prazo, isto é, antecedência máxima maior que duas semanas e menor que três meses se enquadra a previsão sub sazonal, conforme figura 1 (NASEM, 2016).



## Prediction forecast timescale

Figura 1. Enquadramento da previsão sub sazonal (tarja em azul) em relação ao seu tempo de antecedência máxima.

Dentre os métodos de estimativas futuras de variáveis hidrológicas existem os modelos empíricos, que realizam ajustes de valores calculados aos observados, e estas relações matemáticas não conferem relação com o comportamento físico dos processos hidrológicos, por exemplo segundo Pedrollo (2000) tem-se os modelos Autoregressivos (AR), médias móveis (MA), autorregressivos de médias móveis (ARMA), redes neurais artificiais (RNA). Os modelos que se baseiam na representação física dos processos hidrológicos por meio de equações diferenciais, são denominados conceituais – estes modelos geralmente possuem módulos de transformação da precipitação em vazão e propagação desta vazão em trechos de rios, também, possuem classificação quanto à consideração da variabilidade espacial dos processos.

Destacam-se entre os modelos conceituais, aqueles que se baseiam na modelagem numérica da precipitação, por exemplo, os Modelos de Circulação Geral (GCM), ilustrados na figura 2. Estes modelos são baseados em equações representativas dos processos físicos e evolução de fenômenos atmosféricos que compõem o sistema climático, que pode incluir a atmosfera, a hidrosfera, a biosfera e a geosfera. Quando acoplados aos oceanos dão origem aos Modelos Acoplados de Circulação Geral (AOGCM), ou quando apenas se objetiva a simulação das condições atmosféricas (Modelos de Circulação da Atmosfera – AGCM). (McGuffie e Henderson-Sellers, 1997; Chou *et. al.*, 2000; Kalnay, 2003; Allasia, 2007; Cuo *et. al.*, 2011; Golding, 2014) - e a

partir destes modelos numéricos obtém-se informações de diversas variáveis meteorológicas, incluindo a precipitação, originando as previsões quantitativas de precipitação (ou *Quantitative Precipitation Forecast – QPF*).

Em geral, estes modelos são resolvidos em uma grade espacial de três dimensões, a latitude, longitude e altitude, e uma dimensão temporal. É comum nestes modelos a representação de processos físicos que ocorrem em escalas pequenas, como a microfísica das nuvens (fluxos convectivos) por meio da parametrização (Kalnay, 2003). Ainda, apresentam como desvantagem a necessidade de grande esforço computacional, modelagem complexa e usualmente estes modelos possuem resolução espacial grosseira, que normaliza grandes áreas em valores médios.

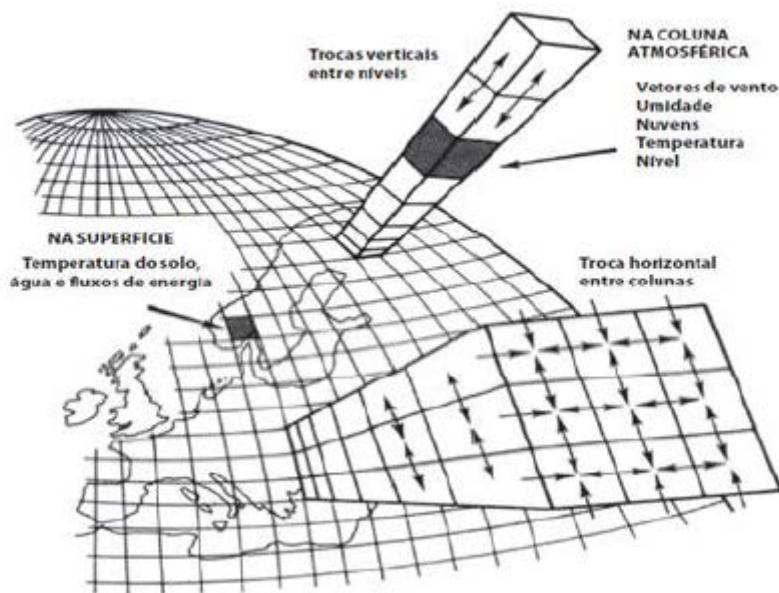


Figura 2. Modelo de Circulação Global de previsão, esquematizado em grade vertical e horizontal. Tipicamente, são definidos um número de camadas verticais, resolução horizontal, fluxos de energia e parametrizações, havendo fluxos horizontais e verticais indicados pelas setas (Sampaio e Dias, 2014).

Ressalta-se que, em vista da escala grosseira dos Modelos de Circulação Global, existem procedimentos para melhorar a resolução da informação, denominados *downscaling*. Tipicamente, aplica-se o *downscaling* dinâmico ou o estatístico: o primeiro, exige maior custo computacional, utiliza subdomínios como condição de contorno para o modelo global, isto é, explora a informação dados observados ou mesmo modelos climáticos de resolução mais fina (modelos regionais); o segundo explora relações estatísticas entre variáveis locais (por exemplo, precipitação) e preditores de grande escala (por exemplo, campos de pressão), e aplica-se estas relações a saída do GCM para estimativa das variáveis locais (Goddard *et. al.*, 2001).

## **2.2. Previsão a longo prazo (clima ou sazonal)**

As previsões realizadas a longo prazo, com o horizonte definido em vários meses, baseiam-se na modelagem da variabilidade climática ou evolução de fenômenos de grande escala, denominados de modos climáticos. Em geral, os oceanos representam a memória do sistema, e a previsão sazonal considera a previsibilidade do seu comportamento, por exemplo, a Oscilação do Atlântico Norte (NÃO), o Modo Anular do Hemisfério Sul (SAM), o El Niño – Oscilação Sul (ENSO), a Oscilação Decadal do Pacífico (PDO), o Dipolo do Oceano Índico (DOI) e a Oscilação Madden-Julian (OMJ) (NASEM, 2010; Yuan *et. al.*, 2015; Tian *et. al.*, 2016; NASEM, 2016; Arnal *et. al.*, 2018).

É importante observar que, os modelos de previsão sazonais não são perfeitos em sua concepção, além disso, muitas das limitações conhecidas nas previsões sazonais (longo prazo ou climáticas) de precipitação são função da baixa quantidade e qualidade de dados, sobretudo nos oceanos, para inicializar os modelos de circulação global (GCM).

Nas previsões hidrológicas de longo prazo objetiva-se, sobretudo, o planejamento e otimização de recursos hídricos, por exemplo, na geração de energia elétrica e otimização de uso da água em reservatórios, na alocação de água para agricultura, gestão de cheias e secas, avaliação da fauna e flora, qualidade da água, transporte e navegação, abastecimento de água, entre outras atividades (Ogallo *et. al.*, 2000; Hamlet *et. al.*, 2002; Neal *et. al.*, 2002; Chiew *et. al.*, 2003; Hsieh *et. al.*, 2003; Changon e Vonnahme, 2003; Olsson *et. al.*, 2004; Nilsson *et. al.*, 2006).

## **2.3. Previsão a curto prazo (tempo)**

Quando a previsão é realizada para um período futuro relativamente curto, usualmente entre poucas horas a duas semanas, utilizam-se metodologias capazes de prever mais acuradamente o padrão atmosférico poucos dias do início do período até que a natureza caótica da atmosfera se torne fator limitante, isto é, pequenos erros (ou interpretações imprecisas) do estado inicial geram grandes erros na previsão. Na figura 3 é ilustrada a relação entre acurácia e técnicas de previsão a curto prazo.

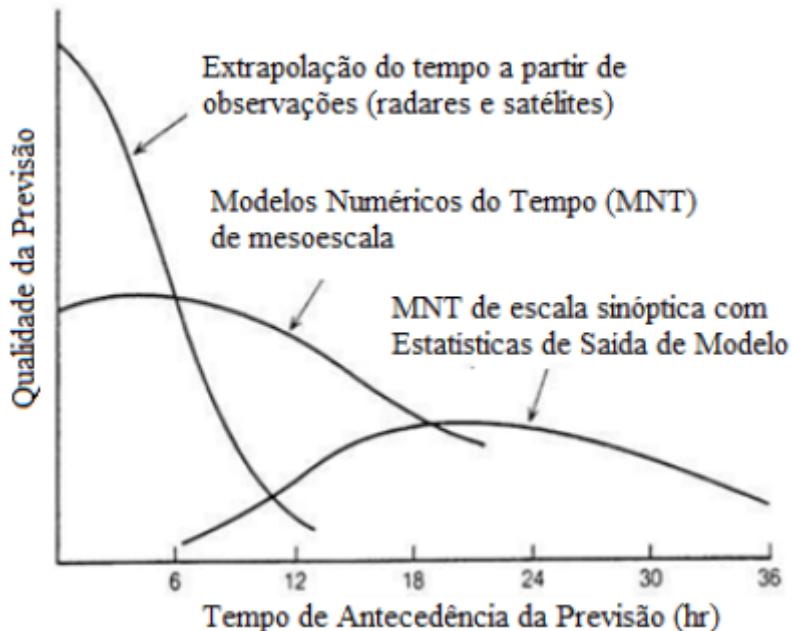


Figura 3. Diagrama da acurácia de metodologias em previsão de curto prazo em relação ao seu tempo de antecedência máxima (adaptada de Pierce *et. al.*, 2012).

A respeito do emprego de modelos numéricos na previsão do tempo, estes iniciaram-se nos anos 90 (Lin *et. al.*, 1993), e resumidamente, estes modelos tem sua acurácia associada a escala da forçante meteorológica associada. Segundo Pierce *et. al.*, (2012) e endossado por Calheiros *et. al.* (2016) as previsões numéricas do tempo demonstram bom desempenho em previsões de eventos convectivos de grande escala, todavia, a previsão da convecção local ainda é deficiente.

A previsão de chuva acumulada encontra dificuldades, sobretudo, devido à baixa densidade de monitoramento do fenômeno precipitação, que possui como característica sua alta variabilidade espacial e temporal. Ainda neste sentido as limitações de equipamentos, como sensores remotos, devem ser consideradas, uma vez que a estimativa destes equipamentos pode não representar todos os tipos de chuva (por exemplo, sistemas convectivos, estratiformes e quentes, que apresentam diferentes características microfísicas) (Calheiros *et. al.*, 2016).

Tipicamente a previsão hidrológica a curto prazo é utilizada no planejamento de ações para minimização dos danos decorrentes de inundações, componentes de sistema de alerta ou compõe hipóteses para definição de diretrizes para o planejamento urbano (Hsu *et. al.*, 2003; Koussis *et. al.*, 2003; Moore *et. al.*, 2005). Estas previsões também são aplicadas no gerenciamento de reservatórios, principalmente para gestão de conflitos dos

usos da água, e operação de barragens com segurança (Bravo, 2006; Bravo *et. al.*, 2008; Bravo *et. al.*, 2009).

#### **2.4. Horizonte sub sazonal como instrumento de previsão hidrológica**

O horizonte sub sazonal é usualmente definido entre duas semanas a alguns meses (Vitart *et. al.*, 2012; Vitart *et. al.*, 2015; Vitart *et. al.*, 2017). A previsão sub sazonal frequentemente é considerada impraticável, situada entre a previsão do tempo (natureza determinística) e a previsão do clima (natureza probabilística); por muitos anos foi considerada um ‘deserto de predictabilidade’, uma vez que seu prazo de antecedência máximo é longo o suficiente para que a memória das condições hidrometeorológicas iniciais sejam praticamente perdidas ao longo das integrações do modelo, e por outro lado é muito curto para que a evolução de fenômenos climáticos tenham grande influência na previsão (NASEM, 2016).

O horizonte sub sazonal, situado na ‘lacuna’ (‘gap’) entre o tempo e o clima, pretende explorar a expertise adquirida das previsões de curto-prazo e sazonal bem desenvolvidas ao longo dos anos, e gerar informações que cumpram demandas a aplicações que se beneficiem de previsões neste horizonte. Em anos mais recentes, os esforços de pesquisadores buscam preencher a lacuna entre tempo e clima, objetivando o desenvolvimento previsões integradas (‘seamless prediction’) e sistemas ‘Ready-Set-Go’. Este conceito é baseado na ideia do aproveitamento “da melhor” previsão em cada horizonte de tempo (Vitart *et. al.*, 2008; Brunet *et. al.*, 2010; Hoskins, 2013; Vitart and Roberston, 2018; Wetterhall and Giuseppe 2018).

Embora seja a previsão em horizonte sub sazonal seja considerada desafiadora, as pesquisas sobre as fontes de previsibilidade como os modos climáticos dominantes (*e.g.* Oscilação Madden-Julian, Baldwin *et. al.*, 2003; Waliser, 2011), um melhor entendimento e interpretação das condições iniciais dos sistemas terrestres (*e.g.* memória inercial na umidade do solo; condições oceânicas; cobertura de neve; trocas de fluxo superfície-atmosfera e oceano-atmosfera, Woolnough *et. al.*, 2007; Sobolowski *et. al.*, 2010; Koster *et. al.*, 2010), e em novas tecnologias e equipamentos, permitem que este paradigma esteja mudando (Hoskins, 2013; Vitart *et. al.*, 2015).

A potencial utilidade atribuída à previsão hidrológica sub sazonal a sazonal (S2S) poderia beneficiar a tomada de decisão em diversos setores, como na gestão de recursos hídricos (*e.g.* controle de enchentes e secas; Pagano *et. al.*, 2002; Hartmann, 2005; Lemos,

2008; O'Donnell e Colby, 2008; Shah *et. al.*, 2017); no planejamento de operações na geração de energia hidroelétrica (*e.g.* antecipando demandas, manutenção de reservatórios, planejamento de manobras operacionais, Robertson *et. al.*, 2014; Foster *et. al.*, 2017, Turner *et. al.*, 2017); na preparação para eventos de grande magnitudes (Braman *et. al.*, 2013; Perez *et. al.*, 2017; Vitart e Robertson, 2018); no planejamento de navegação e transporte fluvial (Meibner *et. al.*, 2017); na produção de safras e comercialização de commodities (Hansen *et. al.*, 2006; Breuer *et. al.*, 2010; Mase e Prokopy 2014); na conscientização antecipada de risco à sociedade (O'Connor *et. al.*, 2005; Patt *et. al.*, 2007; Goddard *et. al.*, 2010; Srinivasan *et. al.*, 2011); à saúde pública (Zhou *et. al.*, 2004; Kuhn *et. al.*, 2005; Thomson *et. al.*, 2006; Kelly-Hope e Thomson, 2008; Jancloes *et. al.*, 2014; Thomson *et. al.*, 2014); entre outros (NASEM, 2016). O setor hidroelétrico pode beneficiar-se em relação às premissas de volume sazonal mantido em um reservatório, que são frequentemente incorporadas ao processo de tomada de decisão, neste sentido, a previsão sub sazonal pode ser usada para fazer os ajustes necessários entre longo prazo e curto prazo, a medida que informações adicionais são derivadas das previsões.

Apesar de serem destacadas as potencialidades, a previsão hidrológica neste horizonte enfrenta desafios inerentes a previsão por conjunto e, em particular, ao prazo de antecedência: determinação do valor econômico das previsões hidrometeorológicas (Wilks e Hamill, 1995; Richardson, 2000; Buizza, 2008); a falta de compreensão e credibilidade na avaliação sistemática de previsões regionais (isto é, algumas métricas de verificação não são diretamente relevantes para os usuários finais, Morss *et. al.*, 2008); a falta de iniciativa de atividades operacionais em adotar os progressos de pesquisas (Pagano *et. al.*, 2002; Lemos, 2008); os produtos disponíveis atualmente podem não se enquadrar imediatamente na estrutura de instituições, o que demandaria a adequação das informações brutas para atender a disparidade entre o produto disponível e a necessidade final (Pagano *et. al.*, 2002); também, destaca-se a pouca comunicação entre os tomadores de decisão (usuários finais) e a comunidade de pesquisadores da área (Lemos e Morehouse, 2005; Suarez e Tall, 2010; Kirchoff *et. al.*, 2013; Buontempo *et. al.*, 2014; Perez e Mason, 2014).

Maiores discussões a respeito das potencialidades, benefícios, deficiências e desafios sobre a previsão sub sazonal a sazonal (S2S), podem ser vistas nas referências NASEM (2010) e NASEM (2016).

Os termos associados aos tempos de antecedência máximo (curto, médio e longo prazo) evidenciam diferenças nas abordagens metodológicas (hipóteses) e aplicabilidades da previsão, conforme ilustra a Figura 4. No eixo vertical o tempo de antecedência (*lead time*) e no eixo horizontal os níveis de tomada de decisão (*decision timescales*). Em seu escopo, na cor bege, a incerteza vai sendo amplificada na medida em que o tempo de antecedência aumenta. Períodos mais distantes do dia inicial da previsão apresentam menor confiabilidade.

Na figura 4 a cor vermelha indica aquelas previsões à curto prazo, que vai de minutos (*nowcasting*) a uma semana, em que se destacam atividades como sistemas de alertas, monitoramento hidrológico, previsões em tempo real, planos diários de navegação, avaliação de disponibilidade energética (e.g. períodos com maior insolação ou precipitação). Em verde é indicado a previsão a longo prazo ou sazonal (*seasonal*), este horizonte de previsão fomenta a geração de informações sobre tendências ou anomalias do clima, gerenciamento de produção agrícola futura em vista de períodos futuros desfavoráveis, na irrigação, manejo de água em períodos de seca, planejamento do uso de recurso hídrico, operação de manobras marítimas em regiões recobertas por gelo. A cor preta indica atividades a serem desenvolvidas em períodos muito longos, ou vários horizontes a longo prazo, isto é, pode ser entendido como projeções que baseiam o planejamento das atividades nos outros horizontes. Por fim, em azul se insere a previsão sub sazonal (*sub seasonal to seasonal*, ou S2S, abrangendo o período de duas semanas a alguns meses).

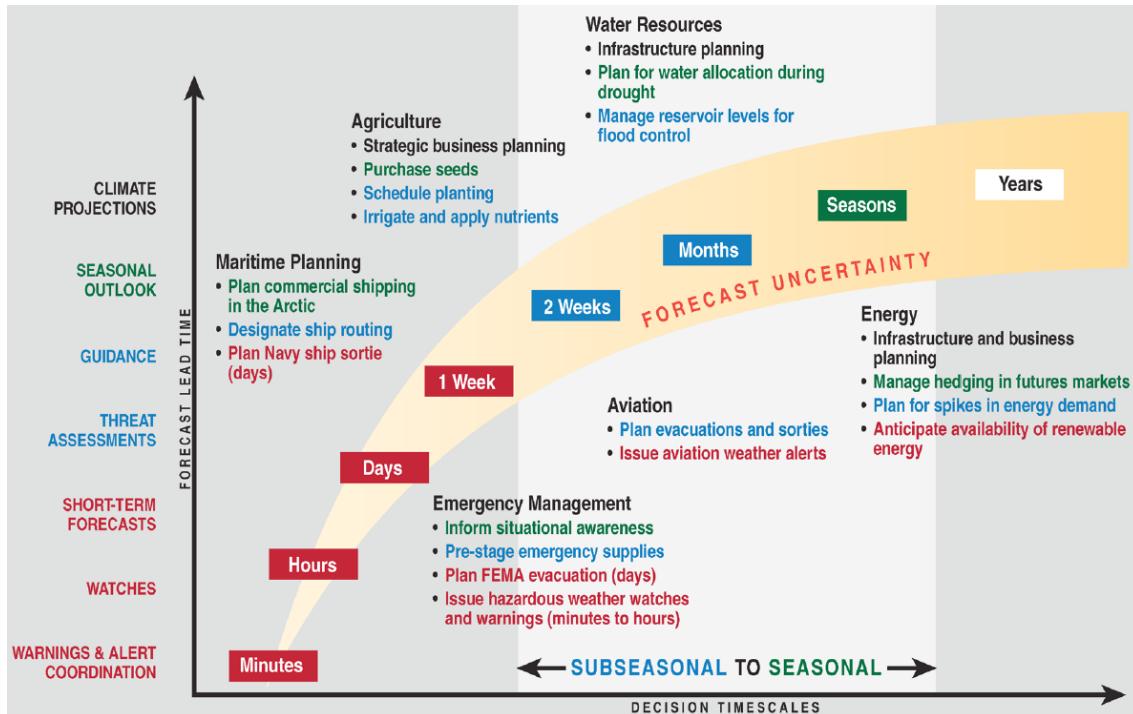


Figura 4. Potenciais aplicações da previsão hidrológica em função do seu horizonte de antecedência e incerteza (NASEM, 2016).

Algumas destas atividades supracitadas, são sensíveis às variabilidades climáticas inter sazonais. Uma boa prática de previsão a prazo sub sazonal pode ajudar no desenvolvimento estratégico e otimização da produção, e redução de impactos em diversas atividades econômicas. Destaca-se a potencial redução na incerteza da avaliação econômica de commodities relacionadas a água, como por exemplo, o preço de geração de energia hidrelétrica (Bravo, 2010).

Pode-se argumentar que os benefícios das previsões sub sazonais tem a oportunidade de atender ou exceder a qualidade das atuais previsões de curto prazo (até duas semanas), também no escopo de mudanças climáticas as estimativas sub sazonais permitem o desenvolvimento de sistemas de alerta antecipados para secas e cheias.

Todavia, no Brasil, o uso de sistemas de previsão baseados em QPF ainda são incipientes, sobretudo devido à grande incerteza associada à estas previsões.

## 2.5. Previsão por conjunto (*ensemble*)

A prática de previsão predominante até algumas décadas atrás era realizada predominantemente com métodos determinísticos, isto é, a estimativa futura era feita a partir de uma única possível trajetória, ou condição de inicialização da previsão (Cloke e Pappenberger, 2009).

Estas previsões determinísticas podem resultar em prognósticos bastante distintos da realidade, uma vez que um sistema de previsão contém diversas incertezas, como aproximações (imperfeições) nos modelos hidrológicos e meteorológicos utilizados, ou registros de dados observados em números insuficientes. Estas incertezas são oriundas da natureza caótica da atmosfera que transfere ao modelo meteorológico grande sensibilidade às condições de inicialização (ou estado inicial adotado), conforme observado inicialmente por Lorenz (1963, 1965, 1969).

A evolução das metodologias de previsão numérica demonstrou que a melhoria na capacidade de representação dos fenômenos físicos nos modelos era insuficiente para obtenção de previsões consideradas boas e que era necessário a consideração e quantificação das incertezas associadas com as observações utilizadas no estabelecimento de condições iniciais da simulação (Buizza, 1997; Buizza *et. al.*, 2008).

Em vista das incertezas inerentes às previsões meteorológicas e climáticas, é praticado nas ciências atmosféricas o emprego de previsões por *ensemble* ou por conjunto. Nesta abordagem são utilizadas diferentes parametrizações ou condições iniciais para geração de cenários equiprováveis, em que cada cenário representa um membro do conjunto, desta maneira, a quantificação das incertezas pode ser traduzida em probabilidades.

Esta abordagem busca a associação da incerteza com o resultado da previsão, de modo que permita a tomada de decisão baseada na melhor hipótese (ou probabilidade). A natureza probabilística da previsão por ensembles, sobressai-se a previsão tradicional determinística por permitir uma interpretação mais ampla dos resultados, sendo possível inferir a trajetória mais provável a partir da faixa de concentração dos membros, e o nível de predictabilidade pode ser verificado pelo espelhamento dos membros por exemplo. (Krzysztofowicz, 2001).

A Figura 5 ilustra a previsão por conjunto (*ensemble*), em que são realizadas múltiplas simulações numéricas, inicializadas com condições iniciais ou mesmo utilizando modelos (parametrizações) diferentes entre si. O resultado é um conjunto de trajetórias para a variável prevista no horizonte de antecedência máximo. Pode-se pensar cada membro do conjunto (linha preta) como uma previsão determinística iniciada com determinada condição inicial e o resultado da previsão é função do conjunto de membros.

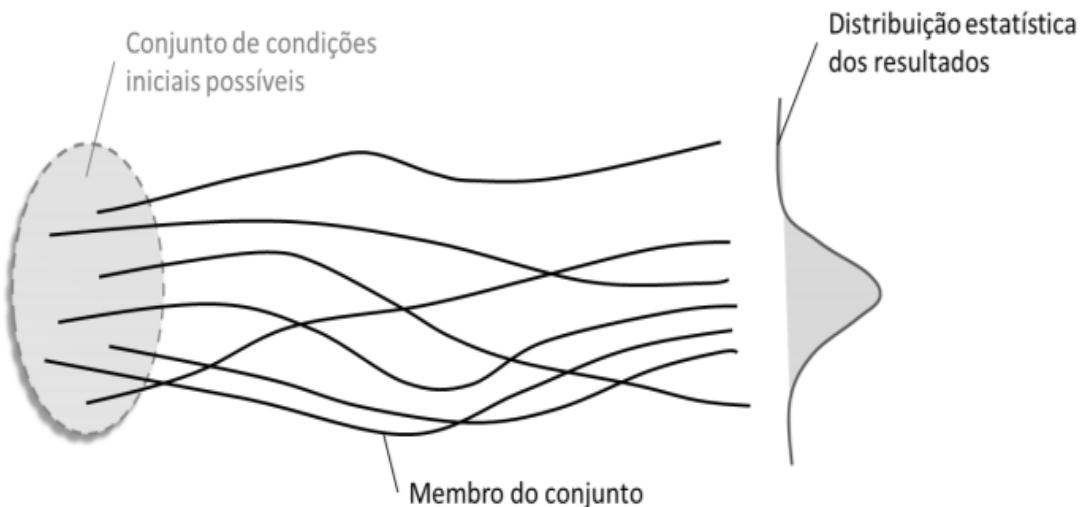


Figura 5. Previsão por conjunto. Cada linha preta corresponde a uma simulação inicializada com diferentes condições iniciais, e a análise dos resultados é em função do conjunto, isto é, da distribuição de probabilidades.

São apontados alguns benefícios associados ao uso de ensembles na previsão hidrológica, sendo eles (Scherrer *et. al.*, 2004; Roulin, 2007; Buizza, 2008; Olsson e Lindstrom, 2008; McCollor e Stull 2008; Bartholomes *et. al.*, 2009; Golding, 2009; Dietrich *et. al.*, 2009; Boucher *et. al.*, 2011; Pappenberger *et. al.*, 2011; Verkade e Wener 2011; Boucher *et. al.*, 2012; Dale *et. al.*, 2012; Ramos *et. al.*, 2013):

- Previsões probabilísticas apresentam melhor desempenho que as determinísticas em termos de estatísticas de quantificação de erros e métricas econômicas.
- A partir de uma previsão bem ajustada, o uso de ensembles permite a quantificação da incerteza, mensurada através do espalhamento dos membros do conjunto.
- Permitem a identificação de eventos extremos com maior ou menor probabilidade de ocorrência.
- Em vista das previsões determinísticas, o uso de ensembles é mais consistente, mensurado pelo grau de concordância entre previsões sucessivas.
- Auxiliam a tomada de decisões relacionadas a operação de obras hidráulicas, execução de planos de emergência, entre outros.
- Beneficia os sistemas de previsão operacionais, aumentando a credibilidade devido a diminuição de emissão de falsos alarmes.

Em vista dos benefícios conhecidos da previsão por conjunto em relação as determinísticas o uso desta abordagem vem sendo empregado também em outras áreas

relacionadas a meteorologia, como a hidrologia. A associação de chuvas previstas (ou QPF) a um modelo hidrológico para obter-se séries futuras de vazões constitui um tipo de sistema de previsão, denominado Sistema de Previsão Hidrológica por Conjunto (ou *Hydrologic Ensemble Prediction System, H-EPS*).

## 2.6. H-EPS

O uso de ensembles operacionalmente na previsão meteorológica é empregado desde a década de 1990 (Buizza *et. al.*, 1999a; Dance and Zou, 2010; Nobert *et. al.*, 2010; Schellekens *et. al.*, 2011; Zappa *et. al.*, 2011; Meller *et. al.*, 2014; Fan *et. al.*, 2014; Siqueira *et. al.*, 2016b), e o uso desta metodologia associado a um modelo hidrológico que transforma a precipitação em vazão dá origem aos sistemas de previsão hidrológica por conjunto (*Hydrologic Ensemble Prediction System*, ou *H-EPS*). Estes sistemas fornecem informações sobre as incertezas das previsões das de vazões e objetivam gerar um conjunto de soluções a partir dos membros que integram o modelo meteorológico e para determinado horizonte de previsão.

A consideração das incertezas, por meio da utilização de previsões meteorológicas por conjunto (*ensemble*) como forçantes do modelo hidrológico, têm demonstrado benefícios quando comparadas com a previsão determinística - em termos de qualidade das previsões de vazão resultantes, que associam o risco ao prognóstico, e na formulação de hipóteses que auxiliem decisões operacionais. Estas melhorias nas previsões hidrológicas utilizando a abordagem probabilística tem motivado o desenvolvimento destes sistemas em diversas localidades do mundo (Cloke e Pappenberger, 2009).

As fontes de incerteza em sistemas de previsão hidrológica são objeto de estudo e aprimoramento nestes sistemas, reconhecidamente os procedimentos de parametrização e a estrutura dos modelos, o estabelecimento de condições iniciais e a incerteza provinda da natureza caótica das previsões meteorológicas são as maiores fontes contribuição (Krzysztofowicz, R., 2001; Pappenberger *et. al.*, 2005; Cloke e Pappenberger, 2009; Cuo *et. al.*, 2011; Pappenberger *et. al.*, 2011; Pappenberger e Brown, 2013).

A Figura 6 traz um esquema da configuração de um *H-EPS*, no qual utiliza-se como forçante do modelo hidrológico, as previsões meteorológicas de precipitação, oriundas de Modelos Acoplados de Circulação Geral (na porção superior), em que previamente a algumas aplicações são aplicados métodos *downscaling*. Na porção à esquerda está ilustrado a inicialização do modelo hidrológico, na qual as informações que caracterizam

o sistema em estudo (por exemplo, bacia hidrográfica) são definidas – sendo que estas informações podem ser provenientes de diversas fontes: observações, produtos de sensoriamento remoto e/ou estimativas numéricas. Após as rodadas da simulação hidrológica, tantas quantas forem os membros do conjunto (*ensemble*), é realizado a etapa de pós-processamento e interpretação dos resultados. No contexto de operação de reservatórios (geração de energia hidroelétrica), pode-se incluir outras etapas na modelagem que utilizariam das saídas do modelo hidrológico como informação de entrada, para geração de informações no planejamento de ações operacionais.

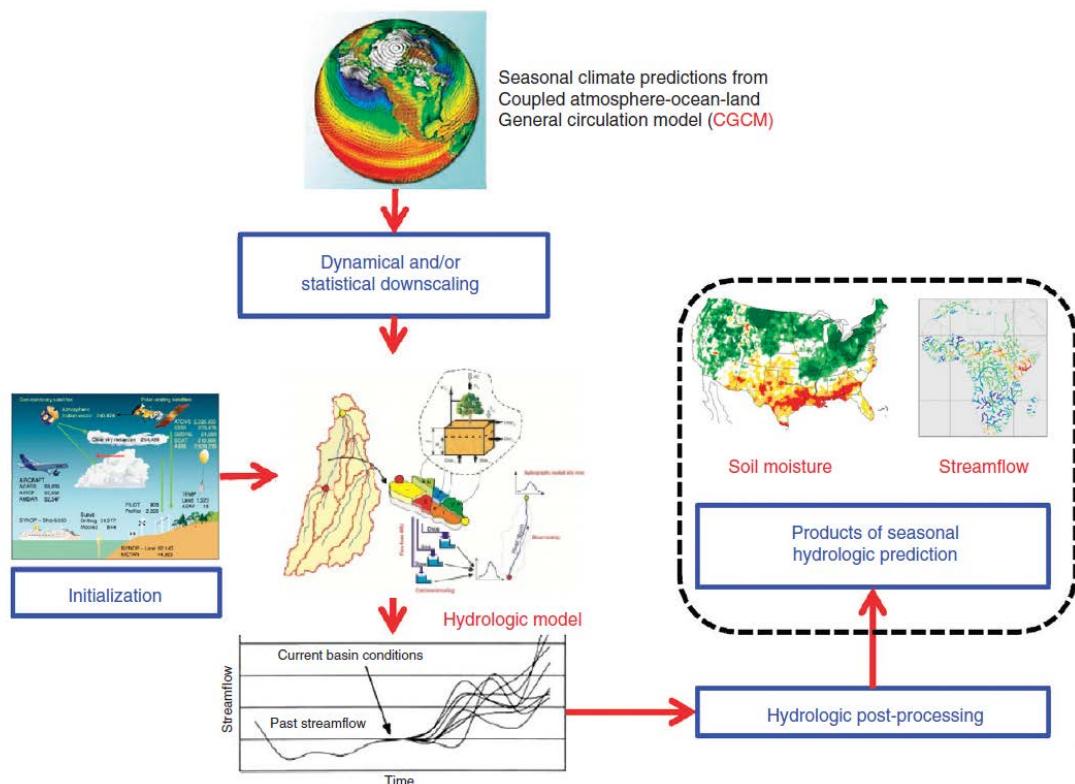


Figura 6. Diagrama da configuração de um *H-EPS*, contemplando etapas de pré-processamento, simulações hidrológicas por conjunto e pós-processamento. (adaptado de Yuan et. al., 2015)

A figura 7 mostra um exemplo de apresentação dos resultados de uma previsão hidrológica por conjunto de curto prazo, no contexto de controle de cheias (estimativa de níveis). Neste exemplo, limiares (probabilidades) de níveis resultantes são ilustrados por manchas de cores que, de modo geral, representam a concentração dos membros nos respectivos limiares.



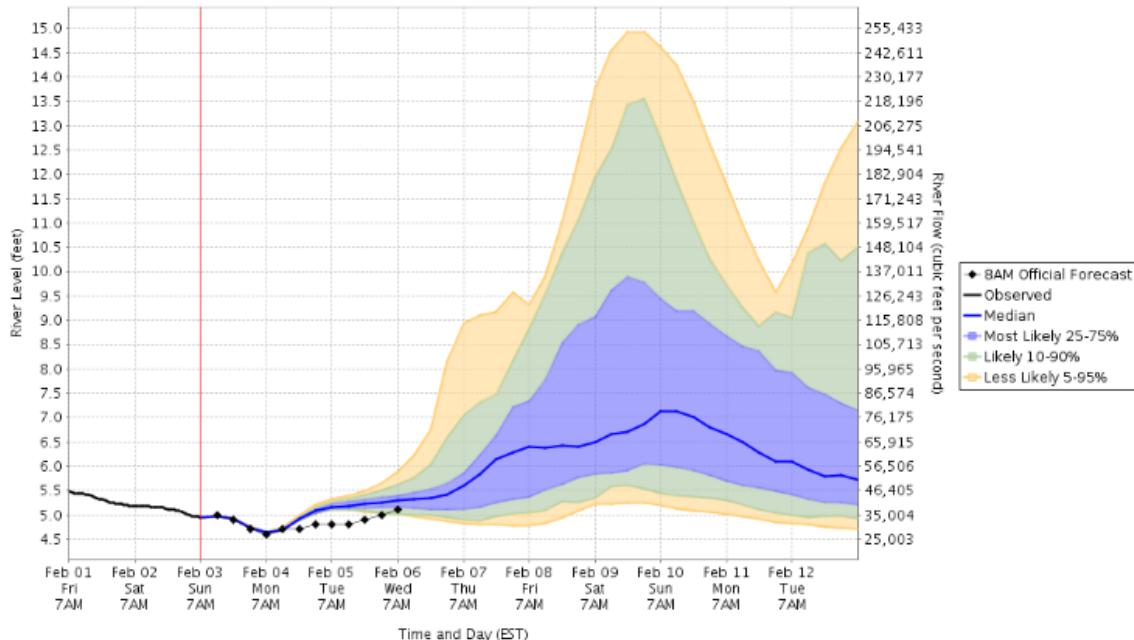
## 10 Day River Level Probabilities

Used to Estimate the Range of Possible River Levels  
[without ENSPOST (Experimental)]

Caution: Official forecast may be updated after this graph is generated.  
For the latest official forecast, go to <http://water.weather.gov/ahps>



### Susquehanna River at Harrisburg, PA (HARP1)



Model runtime: 07:00 AM EST Feb 03 2019  
Middle Atlantic River Forecast Center

Figura 7. Exemplo de resultado de uma previsão hidrológica por conjunto, com horizonte de 10 dias, gerada pelo MARFC Hydro Ensemble Forecast Service – National Weather Service (NOAA). Os limiares representam a concentração dos membros do conjunto em cada faixa de valor.

Embora esta abordagem probabilística tenha sido desenvolvida na meteorologia a mais tempo ainda é recente o desenvolvimento de pesquisas e sistemas operacionais de previsão de vazão por conjunto (*H-EPS*). Ainda, diversos sistemas operacionais utilizam metodologias determinísticas, e o processo adoção da previsão por conjunto exigiria adaptação dos atuais sistemas (Pappenberger e Brown, 2013).

Ainda sobre os desafios acerca da previsão por conjunto, alguns autores destacaram ao longo de suas pesquisas questões a serem resolvidas (Schaake *et. al.*, 2006; Cloke e Pappenberger, 2009; Ramos *et. al.*, 2010; Boucher, *et. al.*, 2011; Meller, 2012; Wetterhall *et. al.*, 2013; Pagano *et. al.*, 2014; Emerton *et. al.*, 2015; Fan, 2015):

- As investigações da qualidade de previsões hidrológicas, como a vazão, aplicando como dado de entrada conjuntos (ensembles) de variáveis meteorológicas previstas, como a precipitação, ainda são incipientes, em relação aos domínios espacial e temporal.

- A inclusão de sistemas baseado em ensembles em operações de empreendimentos (tomadas de decisões) pode se tornar tortuosa, uma vez que esta abordagem requer maior conhecimento sobre o tema, sobretudo para interpretação dos resultados.
- O manejo de informações e dados digitais disponíveis pode se tornar complexa, e requer grande capacidade de armazenamento e processamento computacional, bem como exige recursos humanos especializados.
- Um sistema de previsão hidrológica por conjunto é muito mais custoso e complexo que a previsão determinística, também em termos financeiros – sobretudo, o processo de geração das previsões meteorológicas (dados de entrada ao modelo hidrológico). Portanto o seu desenvolvimento requer o engajamento dos setores beneficiados e a promoção de seu uso em ambientes científicos e acadêmicos.

Ressalta-se que ainda é incipiente a aplicação destes sistemas em grandes bacias tropicais brasileiras, como o caso das principais bacias que alimentam os reservatórios hidroelétricos brasileiros. Nestas bacias as previsões de vazões apresentam grande potencial para beneficiar gestão e gerenciamento das afluências e persistência da vazão.

## **2.7. Verificação de previsões por conjunto**

O processo de verificação tipicamente objetiva avaliar a correspondência entre os valores previstos (simulados) e uma referência, como por exemplo os valores observados. Em um sistema de previsão a verificação é útil para avaliação de aplicações singulares, como a antecipação de eventos para proteção de cheias e para estimativas de volume em longo prazo, também na análise do grau de viés das previsões.

A verificação por *ensemble* naturalmente gera mais informações que as determinísticas por considerarem as incertezas aos resultados, deste modo, deve-se verificar a função de distribuição (empírica ou ajustada), medidas de tendência central, espelhamento do conjunto, a somatório dos erros da distribuição em um certo período, e probabilidades de ocorrência de eventos. Tipicamente são avaliados os atributos da qualidade da previsão, conforme Jolliffe e Stephenson (2003) e Wilks, (2006):

- Viés (*bias*): desvios entre os valores previstos e as referências.
- Acurácia (*accuracy*): diferença entre a previsão e a observação (ou simplesmente, erro da previsão).

- Correlação linear (*correlation*): medida de correlação entre as previsões e observações
- Destreza (*skill*): esta medida de desempenho é aplicada entre sistemas de previsão, no qual mensura-se qual a destreza ou qualidade do sistema estudado em comparação a referência.
- Resolução (*resolution*): refere-se à habilidade do sistema de previsão em atingir boa probabilidade de previsão em eventos diferentes, por exemplo em períodos secos e chuvosos. Um sistema capaz de obter bom desempenho períodos distintos é tido de boa resolução.
- Discriminação (*discrimination*): utilizado para avaliar a capacidade de prever a ocorrência de um evento discreto ou dicotomo, por meio da atribuição de um limiar de excedência (*threshold*).
- Agudeza (*sharpness*): mensura a capacidade na tendência de prever eventos extremos (probabilidades extremas, ~0% ou ~100%), é dito agudo o sistema que sugere eventos extremos com alta probabilidade, isto é, se o sistema indica probabilidades extremas com pouca frequência ou alta frequência.

As métricas tipicamente utilizadas em sistemas de previsão são descritas pelo The *Joint Working Group on Forecast Verification Research* do *World Research Programme* (WWRP) na referência (<<http://www.cawcr.gov.au/projects/verification/>>). A Tabela 1, apresenta as métricas com relação ao atributo (qualidade), nome, tipo da previsão (previsão única ou probabilística) e se o evento é dicotomo (ocorre ou não, a partir de um limiar).

Destaca-se que além da “qualidade” da previsão (avaliada pelas métricas dos atributos) há a definição de outras duas propriedades (Murphy, 1993; Pappenberger *et. al.*, 2011): a “expectativa” que se relaciona a expectativa do previsor, inserindo um fator humano na avaliação da previsão; a outra é o “valor”, associado a utilidade da previsão em relação a benefícios (valores) econômicos.

Tabela 1. Compilação de métricas em relação ao atributo, tipo da previsão e evento discreto.

Atributo Avaliado	Nome da Métrica	Tipo da previsão	Evento discreto
Erro	<i>Mean Absolute Error</i>	Determinística	Não
	<i>Mean Square Error</i>	Determinística	Não
	<i>Root Mean Square Error</i>	Determinística	Não
	<i>Mean Continuous Rank Probability Score (CRPS)</i>	<i>Ensemble</i>	Não
	<i>Brier Score</i>	<i>Ensemble</i>	Sim
	<i>Critical Success Index (ou Threat Score)</i>	Ambas	Sim
Viés	<i>Relative Mean Error (ou Relative Bias)</i>	Determinística	Não
	<i>Frequency Bias</i>	Ambas	Sim
Correlação	<i>Pearson Correlation Coefficient</i>	Determinística	Não
	<i>Spearman Rank Correlation</i>	Determinística	Não
Destreza	<i>Mean Absolute Error Skill Score</i>	Determinística	Não
	<i>Mean Square Error Skill Score</i>	Determinística	Não
	<i>Mean Continuous Rank Skill Score</i>	<i>Ensemble</i>	Não
	<i>Brier Skill Score</i>	<i>Ensemble</i>	Sim
	<i>Equitable Threat Score (ou Gilbert Skill Score)</i>	Ambas	Sim
Confiança	<i>Mean CRPS Reliability</i>	<i>Ensemble</i>	Não
	<i>Brier Score Reliability</i>	<i>Ensemble</i>	Sim
	<i>Reliability Diagram</i>	<i>Ensemble</i>	Sim
	<i>Rank Histogram</i>	<i>Ensemble</i>	Sim
	<i>Success Ratio</i>	Ambas	Sim
Resolução	<i>Mean CRPS Resolution</i>	<i>Ensemble</i>	Não
	<i>Brier Score Resolution</i>	<i>Ensemble</i>	Sim
Discriminação	<i>Relative Operating Characteristic Score</i>	Determinística	Sim
	<i>Relative Operating Characteristic Diagram</i>	Determinística	Sim
	<i>Probability of Detection (ou Taxa de Acertos)</i>	Determinística	Sim
	<i>Probability of False Detection (ou Taxa de Alarmes Falsos)</i>	Determinística	Sim
Agudeza	<i>Forecast Frequency Histogram</i>	<i>Ensemble</i>	Sim

### 3. Materiais e Métodos

#### 3.1. S2S

O banco de dados *Subseasonal-to-Seasonal* (S2S) é um produto do projeto de pesquisa em conjunto do *World Weather Research Programme* (WWRP) e *World Climate Research Programme* (THORPEX-WCRP). O objetivo deste projeto é a melhoria nas previsões nos horizontes de previsão entre duas semanas até três meses, promovendo o uso e desenvolvimento de aplicações nestes horizontes.

O banco de dados é apresentado e descrito em Vitart *et. al.*, 2017. Esta base disponibiliza previsões *quasi* tempo real desde o início de 2015 até dias atuais, com tempos de antecedência máximo de até 60 dias, geradas por 11 centros de pesquisa: *Australian Bureau of Meteorology* (BoM), *China Meteorological Administration* (CMA), *European Centre for Medium Range Weather Forecasts* (ECMWF), *Environment and Climate Change Canada* (ECCC), *Institute of Atmospheric Sciences and Climate of the National Research Council* (CNR-ISAC), *Hydrometeorological Centre of Russia* (HMCR), *Japan Meteorological Agency* (JMA), *Korea Meteorological Administration* (KMA), *Météo-France/Centre National de Recherche Meteorologiques* (CNRM), *National Centers for Environmental Prediction* (NCEP), e *Met Office* (UKMO). Cada modelo desenvolvido nos respectivos centros de pesquisa possui configurações e parametrizações distintas, bem como quantidade de membros do conjunto e horizontes de previsão.

A utilização de dados do banco de dados S2S também é motivada por uma série de estudos recentes que instigam o uso da previsão em horizontes sub sazonal para sazonal e que promovem melhoria da qualidade destas previsões e viabilização do uso destas informações em atividades econômicas. (e.g. Brunet *et. al.*, 2010; Vitart *et. al.*, 2012; NASEM, 2016).

Para esta pesquisa foi escolhido o modelo oriundo do *European Centre for Medium Range Weather Forecasts* (ECMWF), reconhecidamente produtora de previsões de alta qualidade. As previsões meteorológicas deste centro são frequentemente exploradas em estudos, por exemplo, no contexto de grandes bacias brasileiras, Fan *et. al.* (2015c) utilizou previsões de curto-médio prazo (15 dias), e demonstraram bom desempenho como forçante do modelo hidrológico MGB-IPH.

O modelo meteorológico ECMWF, na versão CY43R3, é um Modelo Acoplado de Circulação Geral, que integra 51 membros no conjunto, sendo um a partir de condições iniciais não perturbadas (membro de controle ou referência determinística). A frequência de emissão das previsões é de duas vezes por semana (segundas e quintas, UTC 00), com prazo de antecedência máximo de 46 dias. Além disso, este modelo produz um conjunto de 11 membros de previsão histórica (*re-forecast* ou *hindcast*), com o horizonte de previsão correspondente à estimativa em tempo atual, iniciado no mesmo dia e mês, cobrindo os últimos 20 anos ('*on the fly*', por exemplo, um conjunto *re-forecast* consiste em 20 anos e 11 membros, resultando em um conjunto de 220 cenários climáticos), as

quais são utilizadas para calibrar as previsões em tempo atual, ou seja, correção de erros sistemáticos (ECMWF, 2017b).

Ressalta-se que a versão do modelo mudou ao longo do tempo, e para as previsões em tempo atual anteriores a 14/05/2015 realiza a previsão para um horizonte de 32 dias e 51 membros no conjunto. O conjunto *hindcast* é composto por 5 membros e 32 dias de horizonte (ECMWF, 2017b).

Os dados são disponibilizados em escala global, com tamanho de grade variável, no formato NetCDF (Common Data Form). Neste estudo obteve-se com grade de 0.125° e acumulados diários. As previsões podem acessadas em: <https://apps.ecmwf.int/datasets/>.

### **3.2. Dados de Precipitação Observada: MSWEP v2.1**

O produto Multi-Source Weighted-Ensemble Precipitation (MSWEP) na versão 2.1 disponibiliza em formato NetCDF (Common Data Form) dados de precipitação para todo globo em uma grade com resolução de 0.1° decimais e resolução temporal acumulado de 3 horas, cobrindo os anos desde 1979 até 2016. Esta base de dados utiliza informações de estações em campo, satélites e métodos de reanalise de dados e potencialmente pode ser utilizado em modelagem hidrológica com bom desempenho (Beck *et. al.*, 2017; Beck *et. al.*, 2018; Beck *et. al.*, 2019).

Estes dados são validados em escala global utilizando observações de estações e outras fontes ao redor do mundo e podem ser acessados em: <http://www.gloh2o.org/>.

### **3.3. Modelo Hidrológico MGB-IPH**

O modelo Modelo de Grandes Bacias (MGB-IPH; Collischonn *et. al.*, 2005, 2007; Paz *et. al.*, 2007; Paiva *et. al.*, 2013) é um modelo hidrológico conceitual, semi-distribuído que é capaz de calcular a vazão a partir da precipitação. Na versão aplicada neste trabalho, a bacia hidrográfica é dividida em unidades elementares sempre que haja confluência entre trechos de rios ou em pontos específicos, estas unidades são denominadas de minibacias. A variabilidade do tipo de solo e vegetação em cada minibacia é representada por uma Unidade de Resposta Hidrológica – URHs, ilustrado na figura 8.

O balanço de água no solo é obtido pelo excesso da capacidade de armazenamento de água no solo de acordo com uma relação probabilística entre umidade do solo e área

de solo saturado (Collischonn e Tucci, 2005). A estimativa da evapotranspiração é calculada pelo método de Penman-Monteith e a interceptação vegetal é representada por um reservatório cujo volume depende da cobertura vegetal. Os escoamentos subterrâneos e subsuperficial são obtidos por relações lineares e não lineares de acordo com a quantidade de umidade do solo (Paiva, 2009).

A vazão resultante de cada uma das unidades elementares até o curso d'água principal é propagada como por meio de reservatórios lineares enquanto que a propagação do rio pode ser propagada utilizando o método de Muskingum-Cunge, ou ainda, em versões mais recentes do modelo, pelo método inercial.

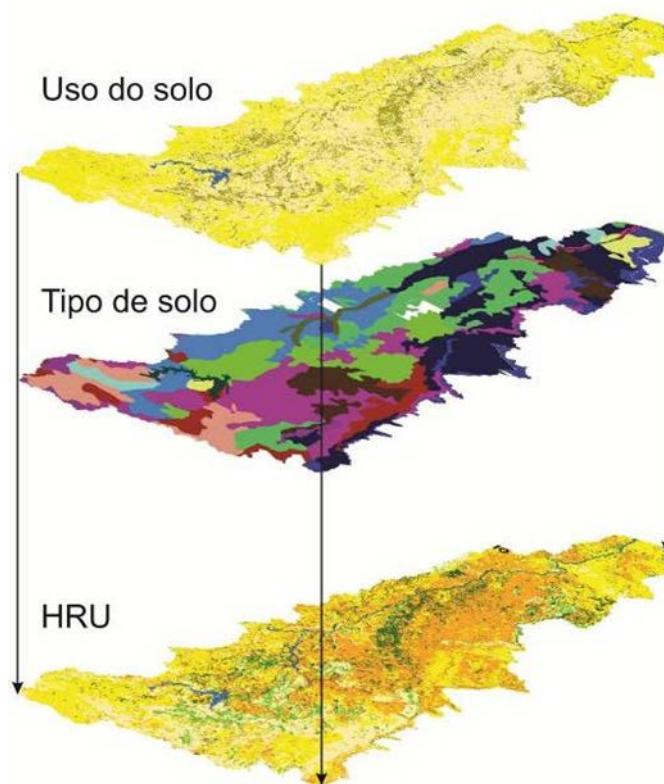


Figura 8. Representação esquemática do procedimento de combinação de mapas de uso e tipos de solo para elaboração de Unidades de Resposta Hidrológica – URH (Collischon *et. al.*, 2014).

Um modelo semi-distribuído como o MGB-IPH exige a adoção de parâmetros, no modelo estes se dividem em fixos e calibráveis. Segundo Collischon e Tucci (2001), os parâmetros fixos se referem a valores que podem ser medidos, como por exemplo, índice de área foliar, albedo, resistência superficial e altura das árvores.

Já os parâmetros calibráveis podem ser modificados em cada uma das URHs, incluindo aspectos como armazenamento máximo no solo, condutividade hidráulica em meio saturado, tempo de retardo dos reservatórios, entre outros. A calibração dos

parâmetros pode ser realizada manualmente ou, ainda, de forma automática, a partir de um algoritmo de otimização multi-objetivo.

O ajuste dos parâmetros que permitem uma representação da bacia hidrográfica envolve a determinação dos valores para uma série representativa de precipitação e vazão conhecidas (Collischonn *et. al.*, 2014). Este processo pode ser feito por tentativa e erro ou utilizando alguma técnica de otimização. Posterior a etapa de calibração, recomenda-se a verificação em que se utiliza o conjunto de parâmetros calibrados com outros dados de precipitação e vazão, de modo que se obtenha um bom ajuste para reproduzir períodos diferentes do utilizado na calibração.

O modelo MGB já foi explorado em estudos de previsão que incluem a abordagem de ensembles como em Meller *et. al.* (2012), Fan *et. al.* (2015c), Fan *et. al.* (2014), Siqueira *et. al.* (2016b), entre outros.

### **3.4. MGB-IPH aplicado a Bacia do Rio Paraná**

A área estudada nesta dissertação é a Bacia do Rio Paraná (BRP), dentro do território brasileiro, cobrindo regiões do Centro-Sul do País até a usina hidroelétrica binacional de Itaipu (confluência do Rio Paraná com o Rio Iguaçu). A BRP é um dos sistemas hidráulicos mais importantes da América do Sul, responsável por mais de 50% da produção hidroelétrica do País (Adam *et. al.*, 2015).

Nesta bacia, estão concentrados mais de 150 grandes reservatórios para geração de energia ao longo do Rio Paraná (rio principal) e seus tributários – alguns dos mais importantes são os Rios Grande, Tietê, Paranapanema e Iguaçu (ANEEL, 2008). Além do potencial hidroelétrico, alguns destes cursos d'água constituem importantes hidrovias brasileiras, por exemplo, o trecho Tietê-Paraná.

A BRP tem uma área total de aproximadamente 907,000.00 km<sup>2</sup>, com limites localizados nas coordenadas 15.450 S até 26.850 S, 43.580 O até 56.110 O, conforme mostra a figura 9.

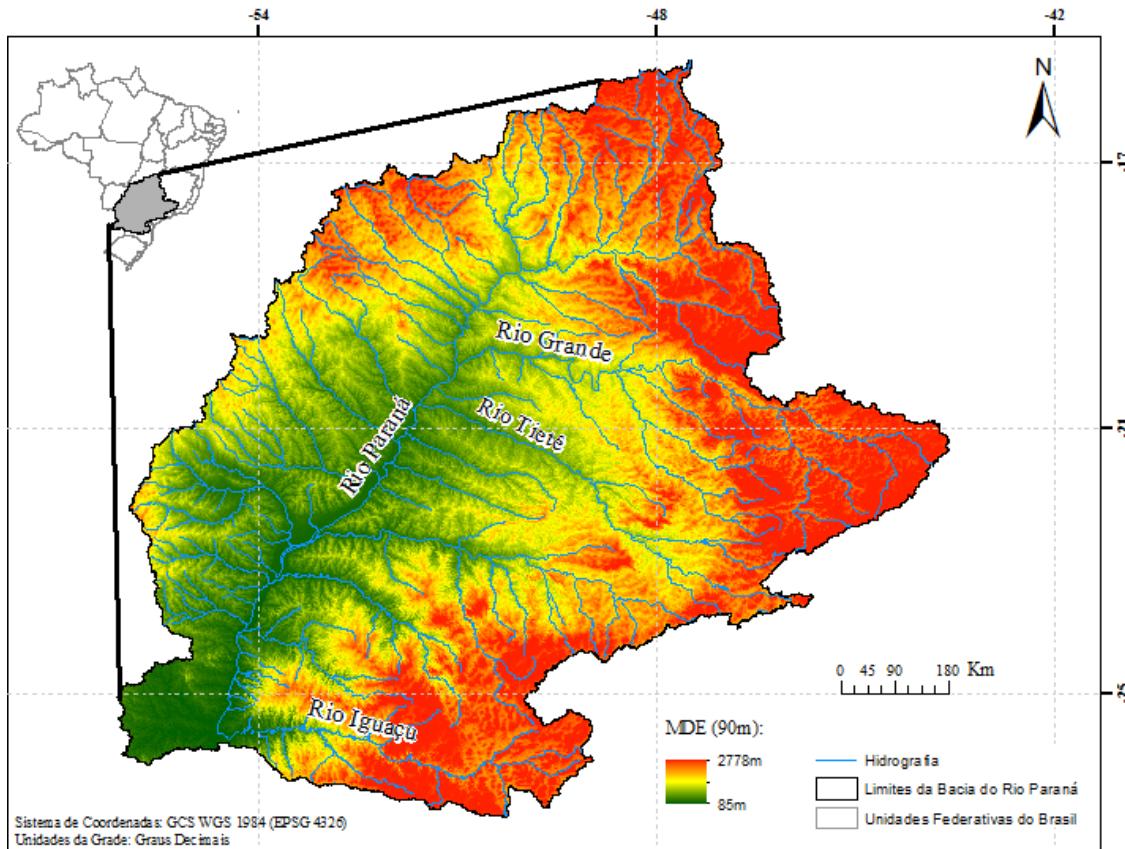


Figura 9. Bacia do Rio Paraná (BRP), em destaque alguns dos principais cursos d'água, relevantes a esta dissertação.

A Bacia do Rio Paraná apresenta diferentes regimes hidrológicos dentro de seu grande território, apresentando sazonalidade distintas em porções da bacia. As regiões mais ao norte tendem a apresentar clima tropical, com invernos secos e verões chuvosos e eventos de precipitação predominantemente convectivos, ao passo que, ao sul as chuvas são mais regularmente distribuídas nas estações (Siqueira e Martins, 2018).

A coordenação da geração e transmissão hidroelétrica é de responsabilidade do Operador Nacional do Sistema Elétrico (ONS), usualmente a ONS utiliza previsões de vazões médias diárias com horizonte de médio prazo para realizar a gestão e gerenciamento da geração de energia (ONS, 2011, 2012a, 2012b, 2014), em que se utilizam metodologias diversas, como modelos estocásticos e modelagem física da bacia conjuntamente com a utilização de variáveis hidrometeorológicas previstas.

O modelo utilizado neste estudo é uma versão do modelo preparada para bacia do Rio Paraná e que vem sendo aprimorada para aplicações diversas (Fan *et. al.*, 2012; Pontes *et. al.*, 2012; Pontes *et. al.*, 2013; Adam *et. al.*, 2014; Adam *et. al.*, 2015; Colossi *et. al.*, 2017a; Colossi *et. al.*, 2017b) utilizou a mesma configuração dos parâmetros que (Fan *et. al.*, 2012; Pontes *et. al.*, 2012; Collischonn *et. al.*, 2014).

Na calibração do modelo foi utilizado o período de 1975 até 1995 dada a melhor disponibilidade de dados e para verificação foi feita para 1995 até 2010. A Figura 10 ilustra a bacia do Paraná discretizada em 1424 minibacias e um mapa de Unidade de Resposta Hidrológica, demais definições e configuração do modelo MGB-IPH aplicado nos estudos que compõem esta dissertação são descritos em Collischonn *et. al.* (2014).

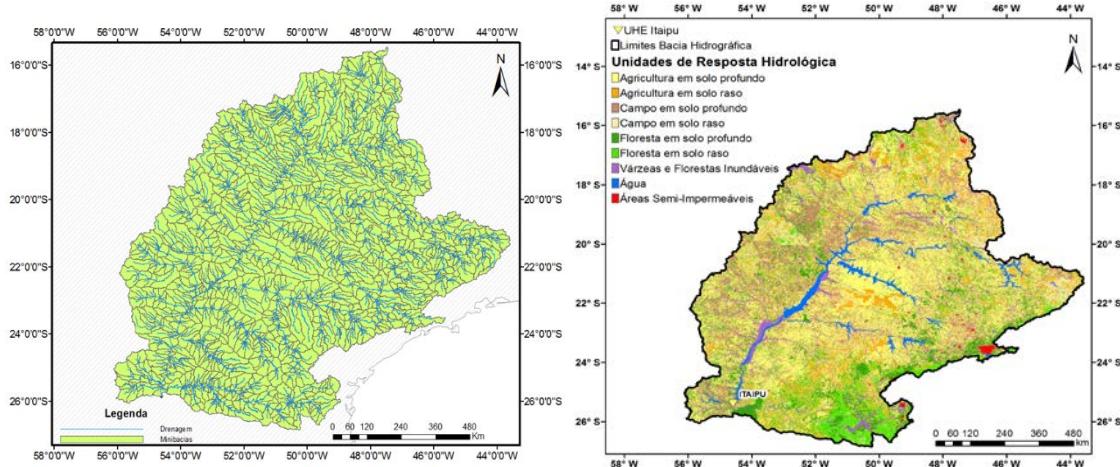


Figura 10. a) Discretização em 1424 minibacias e seu respectivo trecho de rio associado. b) As URHs que compõem a bacia.

Esta região hidrográfica ainda é carente em estudos de previsão hidrológica a médio-longo prazo (horizonte subsazonal), sobretudo por ensembles (abordagem probabilística) e este tipo de estudo pode trazer benefícios ao gerenciamento e operação de diversos empreendimentos instalados na região.

#### **4. Evaluation of Sub seasonal to Seasonal (S2S) Precipitation Forecasts for Hydrologic Forecasting Purposes Within Paraná River Basin – Brazil.**

Este capítulo aborda sobre a previsão numérica de precipitação por conjunto, em horizonte sub sazonal. Em vista da crescente utilização destas previsões numéricas em modelagem hidrológica (por exemplo, de vazões), este trabalho é instigado pela investigação dos erros associados a estes dados e suas potencialidades em aplicações futuras. Pode-se explorar a utilização dos dados *real-time* (previsão em tempo atual), bem como as previsões feitas para o passado, *hindcasts* ou *re-forecasts* – estas últimas aplicadas para correção de erros sistemáticos do modelo meteorológico utilizado.

É apresentado inicialmente uma revisão bibliográfica a respeito da previsão numérica do tempo por conjunto, e em específico no horizonte sub sazonal, que por muitos anos foi considerado impraticável. Percebe-se que, a previsão neste horizonte está adquirindo maior relevância na previsão numérica e sendo viabilizada, sobretudo, pelo empenho em pesquisas sobre as fontes de predictabilidade (modos climáticos) que mais influenciam a evolução de fenômenos neste horizonte; a melhor representação dos fenômenos e interações atmosfera-troposfera em modelos globais; evolução de dispositivos e equipamentos que permitem um melhor monitoramento hidro meteorológico dos sistemas terrestres. Ainda são revisadas a literatura de aplicações que se beneficiariam destas previsões, bem como as carências existentes na prática atual da previsão sub sazonal por conjunto.

No desenvolvimento do trabalho é realizado um estudo em que se utilizou dados de previsão sub sazonal por conjunto, gerados pelo centro de pesquisa *European Centre for Medium-Range Weather Forecasts* (ECMWF), disponíveis no banco de dados mantido pelo projeto *subseasonal-to-seasonal* (S2S). Nesta aplicação utilizou-se a estrutura de modelagem hidrológica semi-distribuída do Modelo de Grandes Bacias (MGB-IPH). Nesta abordagem, subdividiu-se a bacia de estudo em unidades, as minibacias, nas quais a coordenada do centroide foi utilizada para interpolação dos dados da previsão meteorológica e geração das séries de precipitação pontuais. Ainda, pode-se explorar as metodologias do mapeamento quantil e erro médio para remoção de erros sistemáticos (viés) destes dados. Os resultados dão indicativa dos erros associados aos dados brutos, e após a correção de vieses, para aplicações hidrológicas.

Este capítulo apresenta-se na forma de um artigo científico, escrito em língua inglesa e submetido na Revista Brasileira de Meteorologia (RBmet) e ainda se encontra em processo de revisão.

## Abstract

The sub seasonal timescale is nowadays considered a predictability desert in hydrological forecasting systems, although it is still a potential tool to be employed in many applications, for both scientific and operational purposes. More recently, the community of forecasters is engaged towards devising a seamless prediction system, encompassing projections within sub seasonal lead times as well. In this study, assessments aimed towards gauging the quality and usefulness of sub seasonal precipitation forecast for further hydrologic forecasting purposes are performed. The case study is conducted within the Paraná River Basin (PRB) – one of the most important hydroelectric producing regions in Brazil. The sub seasonal forecast data were evaluated in a raw format and in an unbiased format, by using the quantile mapping technique and the mean error method. Resulting in the evaluation of sub seasonal forecasting and demonstrating the added value that the bias correction step can have within the studied basin.

### 4.1. Introduction

Precipitation plays a key role in the hydrologic cycle, and it is considered one of the most difficult variables to forecast. Over the last few decades, the use of quantitative precipitation forecasts (QPF), which originated from numerical weather prediction (NWP), through both scientific and operational purposes, has increased (Buizza *et. al.*, 1999a; Krzysztofowicz, 2001; Cuo *et. al.*, 2011; Fan *et. al.*, 2014; Fan *et. al.*, 2015c).

Along with the development of improved environmental monitoring and technologies (i.e. increased spatial and temporal resolution, resulting in more accurate forecasts), opportunities have been created to advance the coupling of QPFs to forecasting operations, such as streamflow predictions (Bartholmes and Todini, 2005; Fan *et. al.*, 2015c; Yuan *et. al.*, 2015; Bell *et. al.*, 2017; Greuell *et. al.*, 2018).

The ensemble prediction technique is employed to overcome some restraints placed around traditional deterministic quantitative precipitation forecast, which is primarily associated with the uncertainties and errors of the incapability to correctly (or sufficiently) know and appropriately represent the initial hydro-meteorological conditions, climate drivers and the structure of numerical models (Krzysztofowicz, 2001, 1998; Buizza *et. al.*, 1999a; Hamil *et. al.* 2008; Lettenmaier, 2008, Buizza and Leutbecher, 2015). This approach allows for the evaluation of a range of future atmosphere states, and, since the early 90's, has become the conventional way to assess the uncertainties in various

forecasting operations (Buizza, 2008; Cloke and Pappenberger, 2009; Fan *et. al.*, 2015a; Fan *et. al.*, 2015b). Ensemble forecasting is commonly used at many operational weather prediction facilities such as, for example, the European Centre for Medium-Range Weather Forecasts (ECMWF – Europe) and the Centro de Previsão de Tempo e Estudos Climáticos (CPTEC – Brazil).

An ensemble prediction system may represent the uncertainties that arise from inaccuracies in the forecast model, by engaging each individual element, assessing the effect of random errors (Palmer *et. al.* 2007; ECMWF, 2017a). However, the models can still be contaminated by systematic errors, or biases, that affect the entire ensemble. Therefore, post processing of one's QPFs constitutes an important step in previously operational or scientific use of the forecast (Buontempo *et. al.* 2014; Cui *et. al.* 2011, ECMWF 2017a).

Over the past decades some progress has been made in short and medium-range forecasts, up to two weeks, which is also called weather prediction. Likewise, seasonal-range predictability (long-term, or climate prediction), ranging from one to several months, primarily aims to predict the averages over the target period, which are more related to slowly evolving components of the climate system, such as sea surface temperature and soil moisture. Moreover, it includes, as predictability drivers, large-scale climate patterns such as El Niño-Southern Oscillation (ENSO), the North Atlantic Oscillation (NAO), the Pacific-North American pattern (PNA), the Southern Annular Mode (SAM), and the Indian Ocean Dipole (IOD) (Yuan *et. al.*, 2015; Tian *et. al.* 2016; Arnal *et. al.* 2017; NASEM, 2010; NASEM, 2016).

In more recent years, the forecasting research community's endeavors are seeking to 'bridge the gap' between weather and climate, moving toward to a 'seamless' prediction and development of 'Ready-Set-Go' systems (Vitart *et. al.* 2008; Brunet *et. al.* 2010; Hoskins, 2013; Vitart and Roberston, 2018; Wetterhall and Giuseppe 2018). The prediction time-frame within the 'gap' (over two weeks and less than a few months), is also called as sub seasonal to seasonal forecast. Its main objectives are to include the well-established expertise of weather and climate researchers along with fulfilling the demands for applications that fall within that time range (Vitart *et. al.* 2012; Vitart *et. al.* 2015; Vitart *et. al.* 2017).

The sub seasonal time range is often considered challenging: it is situated between the weather (deterministic predictable or initial condition problem) and climate

(probabilistic predictability from slowly varying conditions); for many years, it has been referred to as a ‘predictability desert’. Once the lead time is long enough that the memory of initial hydro-meteorological conditions is virtually lost, where it is too short for the variability of slowly evolving components of the earth system have a strong influence (Vitart *et. al.* 2017). Although, the researches on sources of sub seasonal predictability such as the dominants climate drivers (e.g. Madden-Julian Oscillation, Baldwin *et. al.*, 2003; Waliser, 2011), better acknowledgment of earth systems initial conditions (e.g. Inertial memory in soil moisture; Snow cover; Ocean-Atmosphere flux exchanges, Woolnough *et. al.*, 2007; Koster *et. al.*, 2010; Sobolowski *et. al.*, 2010) and technologies, are allowing this paradigm to change (Hoskins, 2013; Vitart *et. al.* 2015).

The potential usefulness attributed to hydrological sub seasonal to seasonal (S2S) prediction could support decision-making across many sectors, as in water supply management (e.g. flood and drought control, Pagano *et. al.*, 2002; Hartmann, 2005; Lemos 2008; O’Donnell and Colby, 2008; Shah *et. al.*, 2017), hydropower operations scheduling (e.g. anticipating demands, reservoir maintenance, water trading and hedging, Robertson *et. al.*, 2014; Fan *et. al.*, 2015c; Foster *et. al.*, 2017; Turner *et. al.*, 2017), preparation for high-intensity events (Braman *et. al.*, 2013; Perez *et. al.*, 2017; Vitart and Robertson, 2018), shipping and navigation planning (Meibner *et. al.*, 2017), crop production and commodity trading (Hansen *et. al.*, 2006; Breuer *et. al.*, 2010; Mase and Prokopy 2012), societal hazard awareness (O’Connor *et. al.*, 2005; Patt *et. al.*, 2007; Goddard *et. al.*, 2010; Srinivasan *et. al.*, 2011), public health (Zhou *et. al.*, 2004; Kuhn *et. al.*, 2005; Thomson *et. al.*, 2006; Kelly-Hope and Thomson, 2008; Jancloes *et. al.*, 2014; Thomson *et. al.*, 2014;), among others (NASEM, 2016). Especially in the hydropower sector, assumptions of seasonal long-term volume held in a reservoir is often incorporated into the early decision-making process, in which context the sub seasonal forecast can be used to draw the necessary adjustments between long-term and short-term planning, as well as additional information becomes available (NASEM 2016).

Although the potential possibilities are highlighted, prediction on this sub seasonal time range faces inherent challenges: determining the economic value of weather and climate forecasts (Wilks and Hamill, 1995; Richardson, 2000; Buizza, 2008); the lack of understanding and systematic credibility in the evaluation of regional forecasts (i.e. verification metrics are often not directly relevant to users, Morss *et. al.*, 2008); shaping the willingness to adopt research progress into operational activities (Pagano *et. al.*, 2002;

Lemos 2008); currently available products may not fit immediately into an institutional framework, including the need for customization of ‘raw’ forecasted information to fulfill mismatches between available products and the actual need of end users (Pagano *et. al.*, 2002); it is also worth pointing out very few communication pathways between decision makers (end-users) and the community of forecasters (Lemos and Morehouse, 2005; Suarez and Tall, 2010; Kirchhoff *et. al.*, 2013; Buontempo *et. al.*, 2014; Perez and Mason, 2014). One can find more information on sub seasonal to seasonal prediction in NASEM (2010) and NASEM (2016).

This study aims primarily to investigate the potential quality and usefulness of sub seasonal time-range QPFs, defined in this work as a forecast horizon of 46 days, for future hydrological forecasting in Brazilian territory. The tested data were originated from the European Centre for Medium-Range Weather Forecasts (ECMWF), embedded in the S2S (Sub seasonal to Seasonal) project context (Vitart *et. al.* 2017). Additionally, this study was conducted within the Paraná River watershed, where the Itaipu hydropower plant is located, one of the most important regions for hydroelectricity production in Brazil, which could potentially benefit from an ensemble forecasting system to complement the operational prediction chain.

## 4.2. Materials and Methods

### 4.2.1. Study Area

The Paraná River basin is one of the most important hydraulic systems in all of South America. In Brazilian territory, it covers regions from South-Central Brazil to the Itaipu hydropower dam, denoted Paraná River Basin (PRB), shown in Figure 1. The PRB is responsible for more than 50% of Brazilian hydroelectric production, concentrating in the Paraná River and main tributaries (Grande, Paranaíba, Tietê, Paranapanema and Iguaçu) more than 150 large reservoir plants for power generation (ANEEL 2008).

The PRB has a total area of approximately 907,000 km<sup>2</sup>, situated at coordinates 15.450 S to 26.850 S, 43.580 W to 56.110 W. The PRB covers a large area which presents distinct hydrological regimes. The variation of precipitation in the basin is related to the action of air masses over Brazil and presents a seasonal character. In the far north, rainfall is tropical and convective, while in the extreme south it is convective and frontal. The region at the northern end of the basin is characterized by the tropical climate, with dry

winters and rainy summers; while in the southern end it presents regular rainfall, more well-distributed over the seasons (Siqueira and Martins, 2018).

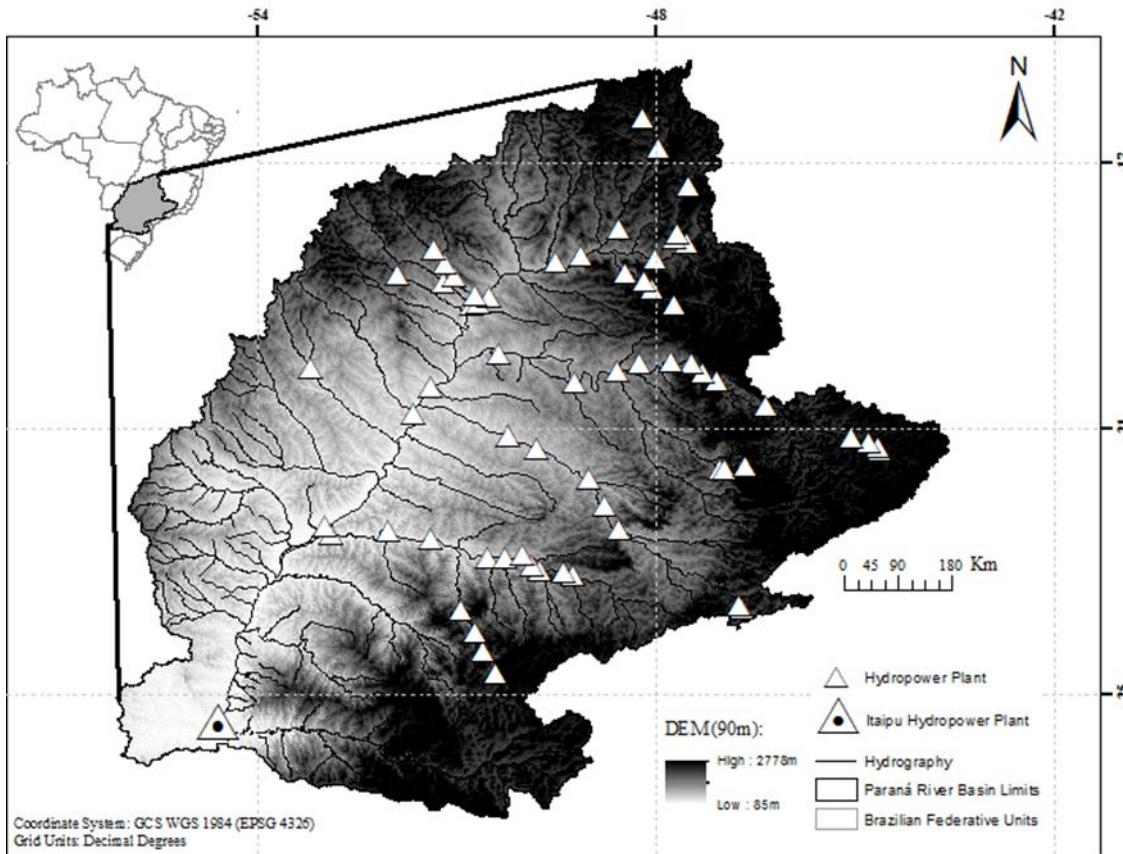


Figure 1. Location of the Paraná River Basin (PRB)

#### 4.2.2. Data

The QPF was provided by the ECMWF CY43R3 model, including the real-time forecasts for 2015 and 2016. In its latest version, the model is based on a global coupled ocean-atmosphere integration of 51 ensemble members, one starting from initial undisturbed conditions (control member) and 50 are disturbed with small perturbations of small amplitude, it runs twice a week (Monday and Thursday, UTC 00) up to day 46 (ECMWF, 2017b). The forecasts used in this study were acquired with  $0.125^\circ$  grid resolution and accumulated daily.

In addition, the model produced twice a week, an ensemble of 11 member historical re-forecast (or hindcast), 46-day lead-time, starting at the same day and month as the real-time, covering the past 20 years ('on the fly', for instance, one hindcast set consist in 20 years and 11 members, resulting in a 220-climate scenarios ensemble), which are used to calibrate the real-time forecasts (i.e. systematic errors correction).

One may note that the model version changed over time and for the real time forecasts before 14/05/2015 model runs for a 32-day lead-time and 51-member ensemble, as for the hindcasts, the ensemble consists of 5-members, and 32-day lead-time. More detailed information about this model can be found in ECMWF (2017b).

The S2S data can be accessed on <https://apps.ecmwf.int/datasets/>.

The QPF were evaluated with the Multi Source Weighted Ensemble Precipitation (MSWEP v2.1) as the observed benchmark, this global dataset covers the years from 1979 to 2016 with a 3-hourly temporal and 0.1° spatial resolution (Beck *et. al.*, 2017a; Beck *et. al.*, 2017b). The use of a gridded precipitation dataset has advantages over local in-situ gauges, by using complementary information acquired through gauges, satellite and reanalysis data, providing estimates for large areas (even the entire globe) and for long temporal availability.

#### 4.2.3. Data Processing

Given the fact that the objective of this study is to verify the QPF for hydrologic forecasting, it was carried out by following a distributed hydrologic model framework, driven by the precipitation forecast on daily timesteps (Yuan *et. al.*, 2015; Fan *et. al.*, 2014; Tucci *et. al.*, 2003; Collischonn *et. al.*, 2005a, 2005b, 2007).

The main river basin is discretized into 1424 unit catchments (i.e. elemental areas based on drainage area and stream confluences, Siqueira *et. al.*, 2016), displayed in Figure 2, areas ranging in 108.07 km<sup>2</sup> to 1100.43 km<sup>2</sup>, in which the centroid coordinate of each of these was used to interpolate representative precipitation series from the gridded S2S data, by taking the nearest QPF grid pixel from the centroid coordinate as its value. The same interpolation had to be done for the MSWEP dataset (observed benchmark), since this dataset was accumulated in daily timestep increments at each centroid.

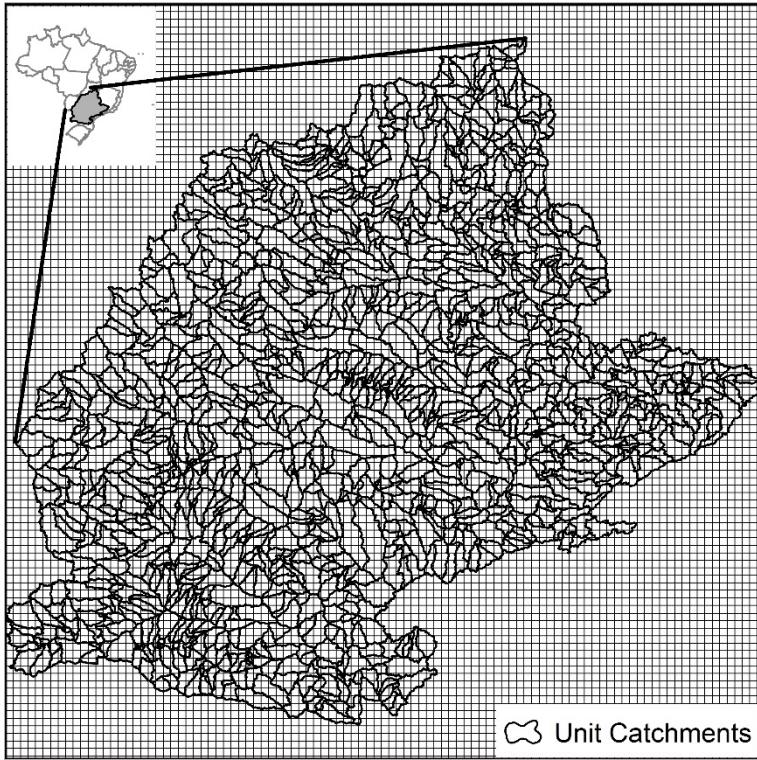


Figure 2. Discretization of the PRB into 1424 unit catchments. The grid corresponds the S2S data over the unit catchments.

#### 4.2.4. Bias Correction

A statistical post-processing of the precipitation forecast was carried out to overcome systematic errors, thusly achieving qualitatively or skillfully enhanced predictions (Thembel *et. al.*, 2011).

#### Quantile Mapping (QM)

One method used to adjust the bias of the QPF model to the observations, was the application of the quantile mapping technique at point-wise locations (centroids). This technique is based on the empirical transformation of Panofsky and Brier (1968), often considered to be the best execution of bias correction methods and has been applied to hydro-meteorological studies (Xu, 1999; Wood *et. al.*, 2002; Hay and Clark, 2003; Boe *et. al.*, 2007; Das *et. al.*, 2008; Maraun *et. al.*, 2010; Piani *et. al.*, 2010; Bardossy e Pegram, 2011; Kallache *et. al.*, 2011; Themebl *et. al.*, 2011; Berg *et. al.*, 2012; Deutschbein and Seibert, 2012; Gudmundsson *et. al.*, 2012; Maraun, 2013; Fan *et. al.*, 2014; Cannon *et. al.*, 2015; Reiter *et. al.*, 2015, 2017).

Quantile mapping technique performs a transformation on the cumulative distributive function of simulated precipitation as it is adjusted to match the cumulative

distributive function of the observations. A correction function can be used, so that the probability associated with each future rainfall forecast (i.e. raw or forecast) is identified from the cumulative distribution function within the data of past simulations, then, the bias corrected value is obtained by corresponding to the same probability in the cumulative distribution function of climatological observations, demonstrated in equation 1.

$$X^{QM} = eCDF_{obs}^{-1} ( eCDF_{sim}(X^{\text{raw}}) ) \quad (1)$$

Where:  $X^{QM}$  is the quantile-mapped rainfall value;  $X^{\text{raw}}$  is the biased forecast;  $eCDF^{-1}$  is the inverse eCDF, a data quantile.

Also, it is worth pointing out that this technique may require some caution when applied in a nonstationary context, as it assumes a stationary bias form (e.g. not verified in analysis of future climates, Kallache *et. al.*, 2011). As a historical re-forecast (hindcast) was used from same model version of real-time forecast to construct the cumulative curves of simulations, we consider the bias as having the same structure as its climatology.

The calibration period to generate the climatological empirical or non-parametric Cumulative Distribution Functions (eCDF; Wilks, 2006), covers past 20-year climatology of dates associated with the forecast lead times (same dates as the historical re-forecasts). In case that some future precipitation value exceeds the range of the correction function, if it is greater than the largest value in hindcasts, a constant mapping is applied: the bias corrected value is then equal to the greatest rainfall in observed climatology. A wet threshold for all data of 1 mm/day was defined, this procedure also ensures a correction to drizzles. Figure 3 shows an example of samples eCDF curves and depicts the correction methods.

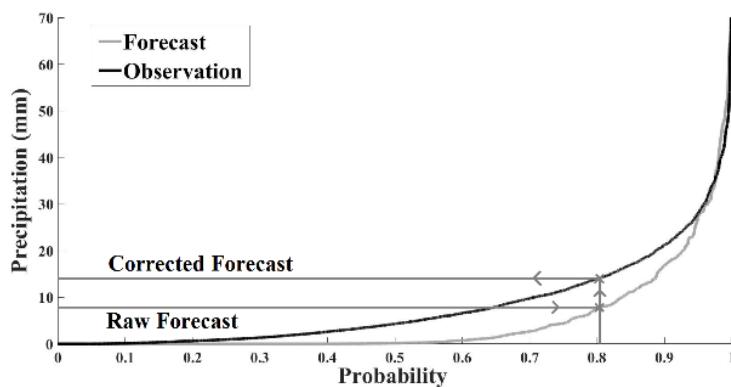


Figure 3. Sampled eCDFs of climatological simulations (gray line) and observations (black line).

## Mean Error (ME)

A second bias correction method was applied using the estimated average bias over the historical past forecasts, hindcasts, similar to Cui *et. al.* 2011, but assigning the same weight to all data, from now on identified as ME. The bias was estimated for each date associated with lead time  $t$ , each unit catchment centroid  $i$  and defined as the difference between the observation and re-forecast, averaged over the past 20 years of real time simulation, following equation 2.

The averaged bias over the trained period, that corresponds to the 20 years of past forecasts is then applied as a correction group to the current forecast at each unit catchment centroid and lead time, the forecast value was estimated following equation 3:

$$bias_{(t,i)} = \frac{1}{n} \sum_{i=1}^n obs_{(t,i)} - refcst_{(t,i)} \quad (2)$$

$$fcst_{(t,i)}_{corr} = fcst_{(t,i)} - bias_{(t,i)} \quad (3)$$

Where:  $bias(t,i)$  is the estimated bias on centroid  $i$  and lead time  $t$ , averaged over  $n = 20$  years;  $obs(t,i)$  is the observation value;  $refcst(t,i)$  is the past forecast or hindcast;  $fcst(t,i)$  is the raw forecast and  $fcst(t,i)_{corr}$  is the mean error bias corrected forecast.

### 4.2.5. Verification Metrics

Statistical verification of S2S forecast quality was considering the area-weighted mean precipitation (observed, raw and bias corrected) for the entire PRB basin, over the verification years, following equation 4. This way, one may quantify the model performance considering one single time series representing the total basin precipitation, that could be used as input for lumped hydrological model. Although, as mentioned before, the bias correction methods were applied following a distributed model framework, on that matter, this may cause shortcomings on the performance metrics of the bias corrected series (e.g. Maraun (2013) points out that for lumped models is recommended performing the correction directly on total precipitation, instead of point-wise series and averaging back to the total).

$$P_{PRB} = \frac{\sum_1^n A_i * P_i}{\sum_1^n A_i} \quad (4)$$

Where:  $P_{PRB}$  is the area-weighted precipitation;  $A_i$  is the area of the unit catchment  $i$ ;  $P_i$  is the precipitation series of the unit catchment  $i$ ;  $n$  is the number of unit catchments.

Following on, using all available real-time forecasts over verification period ( $N = 209$ ), at each timestep ( $t$ ), considering the mean of all 51-ensemble members, the forecasts were evaluated by the Mean Absolute Error (MAE, equation 3) and the Root Mean Squared Error (RMSE, equation 4), against the observed benchmark. The MAE gives the same weight to all errors, measuring the average magnitude of errors at each time step. Meanwhile, the RMSE as a quadratic scoring rule penalizes larger errors, measuring the variability of the error magnitudes. Both metrics are commonly employed in model evaluation studies and provides different insights on model errors, therefore, a combination of metrics is recommended to assess model performance (Chai and Draxler, 2014).

$$\text{MAE}_{(t)} = \frac{\sum_1^N |P_{\text{PRB}f_{(t)}} - P_{\text{PRB}o_{(t)}}|}{N} \quad (5)$$

$$\text{RMSE}_{(t)} = \sqrt{\frac{\sum_1^N (P_{\text{PRB}f_{(t)}} - P_{\text{PRB}o_{(t)}})^2}{N}} \quad (6)$$

The descriptive statistics of monthly 2-year climatology calculated over the verification years for each dataset, is based on the total representative precipitation series (PRB), which is also tabulated. Considering the ensemble mean value of the precipitation series, all daily rainfall within each month was used in the computation of the statistics. Thus, this data can be used to visualize the behavior of precipitative phenomena over the year, allowing to identify wet and dry seasons across the basin. One may also be able to compare the precipitations datasets with the temporal structure over the months.

Furthermore, the assessment of precipitation datasets at each point (unit catchments centroids) was performed through visual analysis on seasonal fields of accumulated precipitation. These fields were generated considering wet and dry seasons, which in this study are defined as the period between October and March for the first, and April and September for the last, averaged over the verification years. Using the punctual (centroids) precipitation series (observed, raw and bias corrected), one may calculate the seasonal average accumulated total precipitation at each location, and afterwards, an interpolation with spatialization of the punctual data. This subjective analysis allows for an evaluation of the S2S forecasts against the observed benchmark on a spatialized basis. It also provides insight into the quantile-mapping method, since it potentially matches the forecast distribution with the long-range observed climatology.

Finally, the evaluation of ensemble performance was executed through the Mean Continuous Ranked Probability (Mean CRPS) Score and the Mean Brier Score (BS).

The Mean CRPS summarizes the quality of one ensemble prediction into a single value. It is obtained by measuring the integrated square difference between the cumulative distribution function (CDF) of the forecast value and the corresponding CDF of the observed (equation 5), where lower values correspond to optimal results. The average across multiple pairs of forecast and observation leads to the mean CRPS.

The numerical value of this score is not directly interpretable as a measure of error, but it can be used as comparative across ensemble and/or deterministic forecasts.

$$\overline{\text{CRPS}_{(t)}} = \frac{\sum_1^n \left( \int_{-\infty}^{\infty} \text{CDF}_{(f_t)} - 1\{f \geq o_t\} \right)^2 df}{N} \quad (7)$$

The brier score is a measure of the average square error of a probability forecast that accounts for the distribution of the ensemble, analogous to the mean squared error of a deterministic forecast but in probabilistic terms. This score measures the error with which a discrete event, such as a given threshold, is predicted.

It is computed by the difference between the probability that a threshold is predicted, considering equiprobability of ensemble members, and the observed outcome, which is calculated as a step function, according to equation 6. The optimal result of the score, which always predicts the occurrence or nonoccurrence of a given threshold, is equal to zero.

$$\overline{\text{BS}_{(t)}} = \frac{\sum_1^N (F_t(TS) - 1\{TS \geq o_t\})^2}{N} \quad (8)$$

### 4.3. Results and Discussion

#### 4.3.1. Accumulated Precipitation Fields

Figure 4 displays the accumulated precipitation fields on wet (a) and dry (b) seasons. A comparison between the raw S2S data and the observed benchmark suggest that the ECMWF model may not appropriately represent the rainfall variability within the basin. Especially in regard to the wet season, it tends to overestimate the precipitation. In addition, the figure indicates that the forecast model slightly overestimated downstream regions on dry season.

This assessment enabled an overall verification, on a spatial basis, of the applied bias correction methods. Since the bias corrected accumulated fields displayed more cohesion to the observed fields, it might have been able to correct some variability and magnitudes of precipitation within the study basin at unit catchment centroid locations.

Consequently, these methods seem to be a suitable way of overcoming some constraints in using the S2S data for hydrological studies, hence improving its potential usefulness for future streamflow forecasting on seasonal time-scales (i.e. more interest on mean values). However, the quantile map method has some limitations (Boé *et. al.*, 2007), such as the temporal self-correlation properties of the S2S series which are not bias corrected. For instance, an overly brief wet spell (period of consecutive days on which the precipitation exceeds a certain amount) or rainfall inter-arrival time in the global model may still exist after the correction. Also, it is indicated that the bias on precipitation may not be unbiased in other variables (e.g. temperature).

Another aspect of the correction methods applied is that we do not perform a separate correction of wet-day frequency (e.g. Schmidli *et. al.*, 2006, 2007; Themebl *et. al.*, 2011).

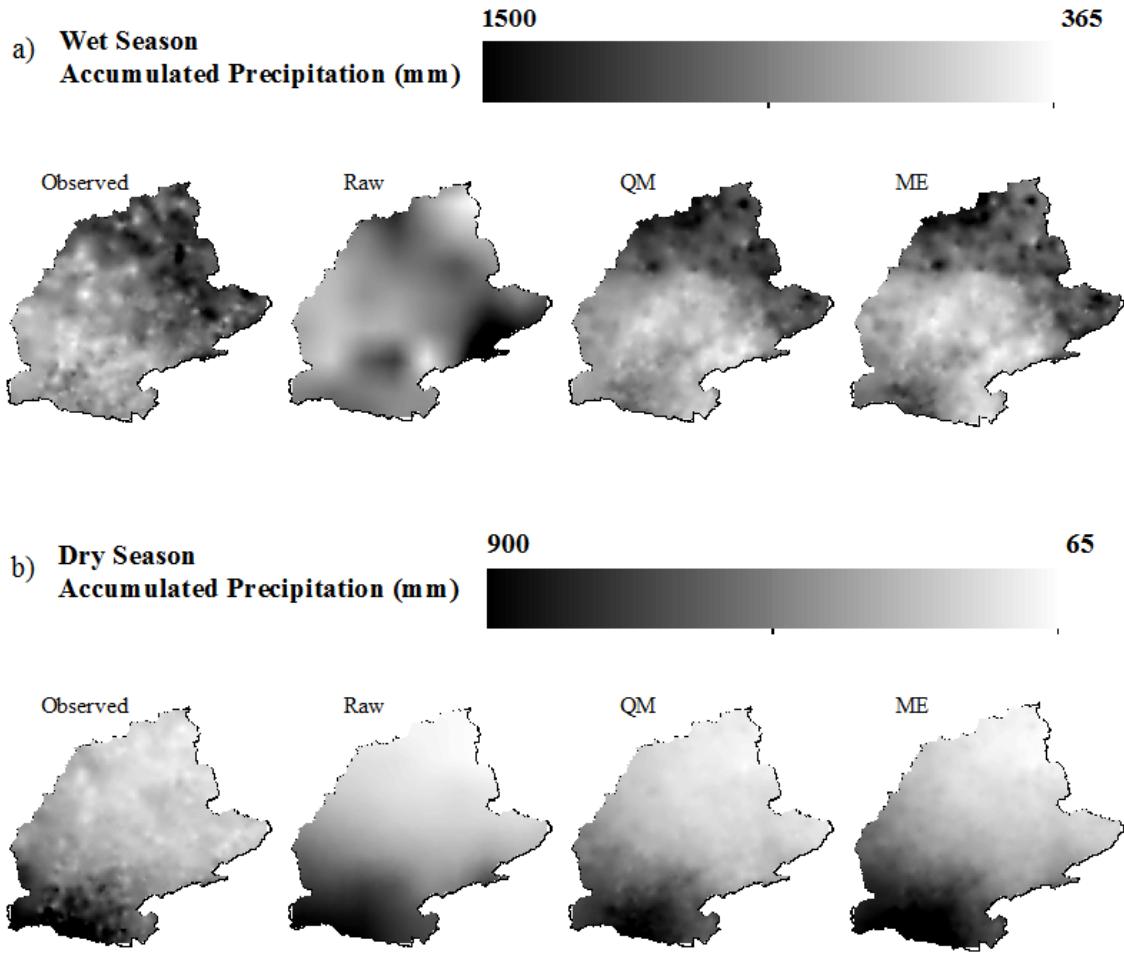


Figure 4. Seasonal averaged total precipitation fields, ranging the years of 2015 and 2016. a) Wet Season (October to March). b) Dry Season (April to September). The first illustration of the basin is the observed dataset, following the raw (without bias correction), the quantile map (QM) and mean error (ME) datasets.

#### 4.3.2. Deterministic Metrics

The descriptive statistics of the entire basin average (PPRB) climatology are shown in tables 1 to 4 for each precipitation dataset. The mean standard deviation (STD) of both raw and bias corrected S2S data suggests little variation in daily rainfall values, which may not represent the observed precipitation that presented larger variability in almost every other month.

For some applications it is valuable to know the dry days' (i.e. precipitation less than 1 mm) frequency over a month. The tables show that the S2S raw model heavily underestimates the number of dry days (NDD). This can be attributed to the averaging procedures (e.g. area-weighting, and ensemble mean), to the overly brief wet-threshold applied, or even the S2S model itself. Though a more robust correction method might be able to improve this matter.

As for monthly mean total precipitation volumes, the bias correction seems to adjust the forecast values to observations more accordingly, reflecting on more accurate mean annual precipitation.

Table 1. Monthly Climatology for the Observed Dataset.

	JAN	FEB	MAR	APR	MAY	JUN	JUL	AUG	SEP	OCT	NOV	DEC
<b>MIN</b>	0	0	0	0	0	0	0	0	0	0	0	0
<b>MAX</b>	22	16	18	25	22	10	16	18	27	17	28	18
<b>MEDIAN</b>	5	6	5	0	1	0	0	0	0	2	5	5
<b>MED</b>	6	7	5	2	3	1	2	2	2	4	6	6
<b>STD</b>	6	4	4	4	5	2	4	3	5	5	6	4
<b>NDD*</b>	5%	2%	8%	57%	44%	70%	63%	73%	68%	35%	8%	2%
<b>VOL</b>	200	192	168	59	108	38	63	47	74	132	188	198

Calculated 2-year Mean Annual Precipitation = 1466.2 mm

\* Dry Days (< 1.0 mm)\*100 / Total number of days on specified month

Table 2. Monthly Climatology for the Raw Dataset.

	JAN	FEB	MAR	APR	MAY	JUN	JUL	AUG	SEP	OCT	NOV	DEC
<b>MIN</b>	0	1,4	0	0	0	0	0	0	0	0	0	1,1
<b>MAX</b>	20	23	19	16	17	13	12	15	25	17	22	18
<b>MEDIAN</b>	8	7	6	3	2	2	1	1	3	5	6	7
<b>MED</b>	8	7	6	3	3	2	1	1	3	5	7	8
<b>STD</b>	2	2	2	2	2	2	2	2	2	2	2	2
<b>NDD*</b>	0%	0%	0%	10%	8%	27%	40%	45%	12%	4%	0%	0%
<b>VOL</b>	245	213	184	93	87	54	45	36	82	150	196	238

Calculated 2-year Mean Annual Precipitation = 1628.7 mm

\* Dry Days (< 1.0 mm)\*100 / Total number of days on specified month

Table 3. Monthly Climatology for the bias corrected Quantile Map Dataset.

	JAN	FEB	MAR	APR	MAY	JUN	JUL	AUG	SEP	OCT	NOV	DEC
<b>MIN</b>	0	0	0	0	0	0	0	0	0	0	0	0
<b>MAX</b>	21	24	23	16	17	14	12	17	25	18	24	17
<b>MEDIAN</b>	7	6	5	2	2	1	1	1	3	4	5	6
<b>MED</b>	7	6	5	2	3	2	1	1	3	4	5	6
<b>STD</b>	2	2	2	2	2	2	2	2	2	2	2	2
<b>NDD*</b>	1%	1%	1%	14%	11%	32%	41%	47%	17%	6%	1%	0%
<b>VOL</b>	211	182	156	74	78	48	43	35	76	129	165	195

Calculated 2-year Mean Annual Precipitation = 1399.3 mm

\* Dry Days (< 1.0 mm)\*100 / Total number of days on specified month

Table 4. Monthly Climatology for the bias corrected Mean Error Dataset.

	JAN	FEB	MAR	APR	MAY	JUN	JUL	AUG	SEP	OCT	NOV	DEC
<b>MIN</b>	0	0	0	0	0	0	0	0	0	0	0	0
<b>MAX</b>	20	21	18	15	17	13	13	14	22	17	22	18
<b>MEDIAN</b>	6	6	5	2	2	1	1	1	1	4	5	6
<b>MED</b>	7	6	5	3	3	2	2	2	2	4	5	6
<b>STD</b>	2	2	2	2	2	2	2	1	2	2	3	2
<b>NDD*</b>	2%	1%	1%	10%	12%	33%	33%	50%	20%	5%	2%	1%
<b>VOL</b>	205	187	163	80	85	51	43	34	66	122	164	202

Calculated 2-year Mean Annual Precipitation = 1404 mm

\* Dry Days (< 1.0 mm)\*100 / Total number of days on specified month

Although this statistical description of the datasets may give insight for the inference of the onset of seasons or anticipating mean sub seasonal (monthly) totals, further analyses on point-wise precipitation series, or even splitting the whole basin into smaller regions that share some hydrologic similarity (e.g. Themelis *et. al.*, 2011), may be necessary to obtain less misleading results.

Figures 5 and 6 show a typical evolution of future precipitation forecast ensemble mean uncertainty for the whole basin series. Within which the inaccuracies tend to

become larger as the lead time further advances in time. Both raw and bias corrected datasets have virtually the same RMSE, or error variability, and it is also seen as a slight improvement on MAE for the QM bias corrected data. It is also demonstrated that the errors in the raw control member are higher than the ensemble mean from initial timesteps. This observation can be extended to the other datasets.

Considering that the rainfall-runoff process over a large basin is a complex non-linear process, a small reduction in errors may improve streamflow predictions.

The S2S model performed better on initial timesteps, when the initial conditions have a stronger influence over the prediction.

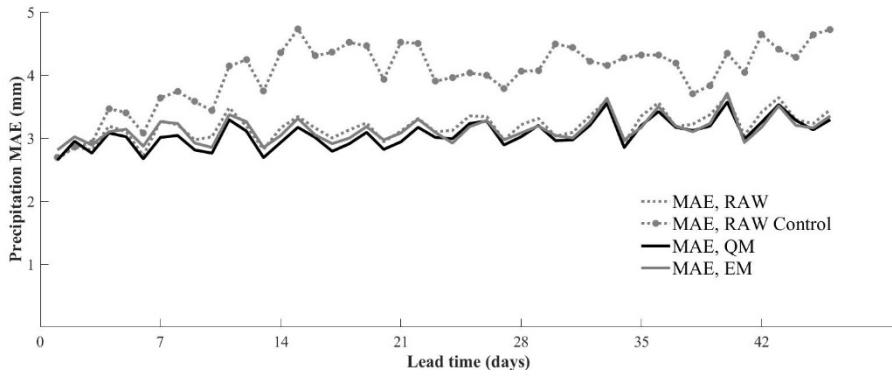


Figure 5. S2S model MAE evolution on further timesteps.

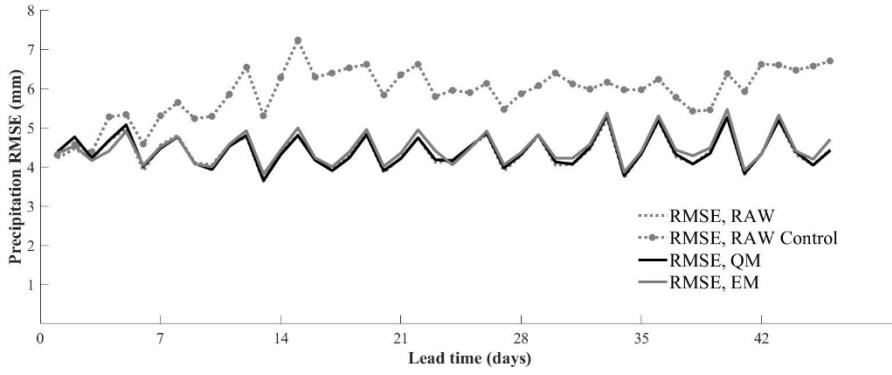


Figure 6. S2S model RMSE evolution on further timesteps.

This matter can constrain the hydrologic application of the method, demanding more accurate information on the time-range over the period of a few weeks. However, through data assimilation techniques (i.e. updating the initial conditions), one can yield material of higher quality on shorter forecast lead times (e.g. Fan *et. al.*, 2015d).

Despite, the analysis may also be improved by correcting the single area-average precipitation series, using the same bias correcting method.

### 4.3.3. Probabilistic Metrics

Figure 10 shows results for the mean CRPS. The behavior of this metric is like those that consider the mean ensemble, which generally tend to increase over the lead times. The mean CRPS for ensemble means showed little variability, between 1.8 mm and 2.5 mm. Directly comparing the mean CRPS of the ensemble's averages with its equivalent deterministic measure (control forecast MAE), indicates that the ensemble forecast has better performance over the forecast lead times. In addition, the bias correction mostly has not improved this metric, only in the initial timesteps is some improvement visible.

The brier score (BS), showed in figure 11, which verifies the detection of discrete events, computed the rainfall score to be 5 mm. For the 5 mm threshold the BS assumed values ranging from 0.16 to 0.22. Also, the bias correction showed little improvement on the brier score.

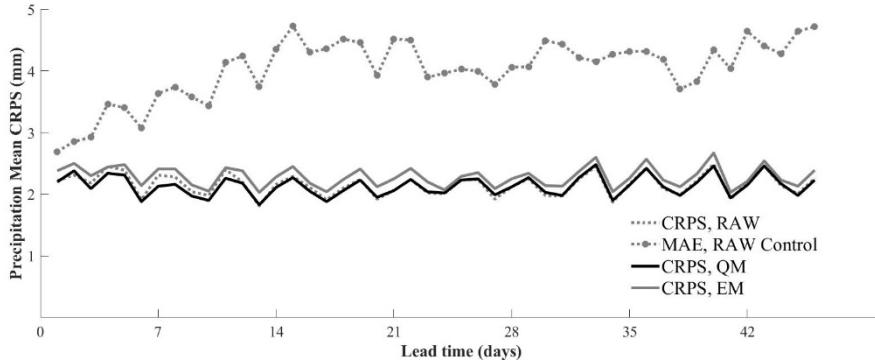


Figure 7. The mean Continuous Ranked Probability Score evolution on timesteps.

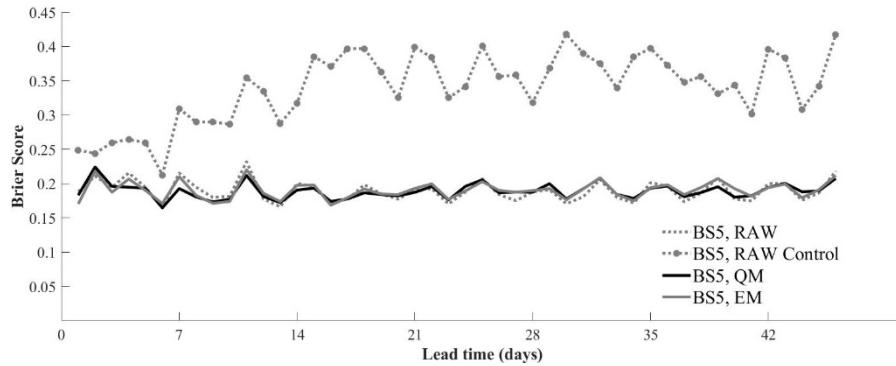


Figure 8. The brier score computed within a threshold of 5 mm.

The results above demonstrate some of the potential uses of future forecast that fall within the sub seasonal time range. In this context, some ways of presenting the results

are displayed, as in projecting the model uncertainty into a single value at each time step (e.g. MAE, RMSE and mean CRPS) or averaging accumulated values within distinct time ranges (e.g. seasonal and intra-seasonal total precipitation).

It is relevant to highlight that the entire PRB presents distinct hydro-climatic conditions within its limits, as noted on precipitation fields (fig. 3) that the higher precipitation volumes occur at distinct seasons within upstream and downstream regions of the basin. Accordingly, before the statistical evaluation metrics, one must adapt the spatial domain (e.g. entire basin, or hydrologic regions) or specifically correct the single representative precipitation series, in lieu of area-averaging the centroids series.

Furthermore, the sort of study presented here may help in answering questions concerning the general usefulness of S2S predictions on a regional basis. Such as: in which location the rainfall event is likely to occur; the wet and dry season onset; the accuracy of longer lead times. Also, an aspect that is not explored within the frame of this study, is association of predictions to vulnerability or expected loss in decision making.

#### 4.4. Conclusions

This Sub Seasonal to Seasonal (S2S) evaluation has been one of the first for hydrological forecasting purposes of future rainfall provided by the database, within one of the most hydropower important regions in Brazil, the Paraná River Basin. In addition to the assessment of raw forecasts, the bias correction method applied to the S2S precipitation dataset remedied the intra-basin variability by following a distributed hydrological model framework.

In general, the quality of the assessed hydrological forecasting showed that the ensemble average MAE ranged 2.6mm to 3.7mm, whilst the control member ranged 2.7mm to 4.8mm. The RMSE varied from 3.6mm to 5.26mm.

The bias correction methods tested produced a better consistency on the spatialized basis of accumulated precipitation totals, which can be an improvement on the spatio-temporal patterns of rainfall.

On the other hand, the bias correction did not show notable improvement on the metrics, therefore it may be an unnecessary step to further hydrologic modeling.

Finally, it is critical to understand the strategies and institutional framework of end users in the light of hydrological sub seasonal ensemble forecasts. On this matter,

future studies within the same database will include evaluation of the results of hydrological forecasts for hydropower plants located in the Paraná watershed.

## **5. Potential of Hydrological Sub-Seasonal Forecasts in Tropical Large-Scale Basins**

O foco deste capítulo é a respeito dos sistemas de previsão hidrológica por conjunto (*H-EPS*, sigla em inglês), os quais utilizam as previsões quantitativas de precipitação como forçantes em um modelo hidrológico. Tradicionalmente, as previsões hidrológicas em prazo sub sazonal (usualmente denominadas de prazo estendido) são obtidas utilizando informações históricas de variáveis meteorológicas, constituindo o método *Extended Streamflow Prediction (ESP)*; Day, 1985). Todavia, devido ao crescente avanço e melhorias na previsão quantitativa destas variáveis, sobretudo a precipitação, oferecem a oportunidade de realizar estas previsões aplicando dados de modelos atmosféricos globais. Baseado nesta motivação, esta pesquisa explora os dados de precipitação quantitativa oriundos do *European Centre for Medium-Range Weather Forecasts* (ECMWF), disponíveis no banco de dados mantido pelo projeto *subseasonal-to-seasonal* (S2S), como entradas ao modelo MGB-IPH.

As múltiplas simulações hidrológicas resultam nas previsões de vazão por conjunto, as quais são avaliadas pontualmente em localidades escolhidas. Também, explorou-se os dados históricos de precipitação observada para geração de *ensembles* baseados nesta informação, constituindo a técnica ESP. Então, avaliou-se o desempenho das previsões S2S métricas estatísticas, indicando as regiões em que estas previsões obtiveram melhor performance, bem como, se fez uma comparação destas previsões com relação aos *ensembles* utilizando informação histórica.

Este capítulo apresenta-se na forma de um artigo científico, escrito em língua inglesa, que está sendo preparado à submissão em periódico científico.

## **Abstract**

The sub-seasonal forecast horizon, defined in this study as up to 46 days, gives rise to many opportunities for research and operational applications. This work is one of the first evaluations of ensemble sub-seasonal meteorological inputs in large-scale basin hydrological modelling within a tropical climate in South America – where one could potentially explore the forecasts for hydropower generation purposes. The precipitation forecast data were provided by the European Centre for Medium-Range Weather Forecasts (ECMWF), within the sub-seasonal-to-seasonal (S2S) project's context. To assess the quality of the forecasts, a statistical evaluation was performed, including a comparison with the traditional extended streamflow prediction (ESP) technique. Results allowed for an estimation of the error magnitudes and the potential to the benefit of the ensemble over the deterministic reference forecast and the ESP approach. We showed that for all locations, the S2S forecasts have advantages over the ESP, although generally their skill deteriorates in lead times after day 30. The evaluation across multiple locations considering its respective drainage area and hydrological conditions, suggests that they are related to the statistical performance outcome.

### **5.1. Introduction**

Streamflow forecasting is consistently a useful tool in the management of water resources. In many applications, the benefits of the predictions increase with lead time. Such as in the river discharge prediction for reservoir and hydraulic structures operations, for example (Fan *et. al.*, 2014; Fan *et. al.*, 2015; Schwanenberg *et. al.*, 2015; Fan *et. al.*, 2016; Anghileri,*et. al.*, 2016).

Over the last decades, the improvement of numerical weather predictions (NWP) enabled the use of quantitative precipitation forecasts (QPF) for many applications, both operational and scientific (Cuo *et. al.*, 2011, Golding 2009, Fan *et. al.*, 2014). Despite the errors and uncertainties associated with the QPF data, it is increasingly being adopted as the preferred input for hydrologic models, aiming towards streamflow prediction.

A common manner of assessing the uncertainties in hydrological forecasting is the implementation of ensembles, in which the hydrological model is usually forced with several quantitative precipitation forecasts, which are referred to as “members” of an ensemble of meteorological model outputs, achieving multiple streamflow scenarios as a result. Providing information on the possibility that an event will occur (Krzysztofowicz, 2001). This approach constitutes what is called a Hydrological Ensemble Prediction System (H-EPS). Additionally, the H-EPS can lead to better decision-making concerning operational hydrological questions. An ensemble forecast system is important in establishing longer lead times than the catchment time of concentration, as well as for

shorter lead times, valuing the prediction on a point of interest, especially near the outlet. These aspects make the H-EPS the best alternative for systems in which it could potentially extend lead times and more efficiently quantify the system's predictability (or unpredictability) (Cloke and Pappenberger, 2009; Cuo *et. al.*, 2011; Cloke *et. al.*, 2013).

The H-EPS have been extensively used for short-range forecasting in flood warning systems and natural disaster prediction, and more recently, the development of technologies has led to large-scale, global flood forecasting (Pappenberger *et al.*, 2013). In addition, medium and seasonal range forecasting constitutes a potential tool for issuing river flow conditions and optimizing water resource management and decision-making (Cloke and Pappenberger, 2009; Emerton *et. al.*, 2016).

Several studies have assessed the performance and usefulness of ensemble forecasting for operational hydrological concerns (Alfieri *et. al.*, 2014; Bennet *et. al.*, 2014; Olsson and Lindstrom, 2008; Roulin and Vannitsem, 2005; Benniga *et. al.*, 2017; Boucher *et. al.*, 2012; Ramos *et. al.*, 2013; McCollor and Stull, 2008; Verkade and Werner, 2011; Dietrich *et. al.*, 2009; Dale *et. al.*, 2012). Particularly, within the tropical and sub-tropical South American context, the recent studies of Fan *et. al.* (2014), Fan *et. al.* (2015), explored medium-range ensemble forecasts primarily addressing inflow verification in hydropower reservoirs; while Siqueira *et. al.* (2016) used short-range ensemble forecasts focused on operational flood prediction.

Recently, the scientific community has been focusing towards better comprehending the efficiency of forecasts across time ranges between short-to- medium (few hours up to two weeks) and seasonal-range (three months to less than a year), which for many years has been called extended-range but has lately been referred to as the sub-seasonal forecasting range. The hydrologic ensemble predictions within sub-seasonal lead times, spanning between two weeks to a few months (Vitart *et. al.*, 2012; Vitart *et. al.*, 2015; Vitart *et. al.*, 2017), are often considered unfeasible due to the high level of uncertainties and legitimately difficult time range required to provide skillful predictions – once placed between the weather (deterministic) and climate (probabilistic) forecast. Despite the possible socioeconomic value that could be derived from this prediction horizon, until recently it had not yet received considerably higher attention than other time ranges. Even though, new advances motivate more appraisals in this timescale (Brunet *et. al.*, 2010; Shapiro *et. al.*, 2010; White *et. al.*, 2017), and the forecasting systems are moving toward a more ‘seamless’ prediction method over the sub-seasonal

horizon (Palmer and Webster, 1993; Palmer *et. al.*, 2008; Vitart *et. al.*, 2008; Brunet *et. al.*, 2010; Hoskins, 2013; Vitart and Roberston, 2018; Wetterhall and Giuseppe 2018), mainly based on the idea of a concatenation of “the best” forecast at each lead time.

The development of hydrological sub-seasonal to seasonal forecasting systems may potentially fulfill the needs of users and enable better decision-making in issues concerning the use of aquatic resources, such as: supporting decision-making in water supply management (e.g. flood and drought control, Pagano *et. al.*, 2002; Hartmann, 2005; Lemos 2008; O’Donnell and Colby, 2008; Bazile *et. al.*, 2017; Shah *et. al.*, 2017; Sene *et. al.*, 2018); scheduling of hydropower operations (e.g. anticipating demands, reservoir maintenance, water trading and hedging, Robertson *et. al.*, 2014; Fan *et. al.*, 2015c; Foster *et. al.*, 2017; Turner *et. al.*, 2017); preparing for high-intensity events (Braman *et. al.*, 2013; Perez *et. al.*, 2017; Vitart and Robertson, 2018); shipping and navigation planning (Meibner *et. al.*, 2017); crop production and commodity trading (Hansen *et. al.*, 2006; Breuer *et. al.*, 2010; Mase and Prokopy 2012); societal hazard awareness (O’Connor *et. al.*, 2005; Patt *et. al.*, 2007; Goddard *et. al.*, 2010; Srinivasan *et. al.*, 2011); public health (Zhou *et. al.*, 2004; Kuhn *et. al.*, 2005; Thomson *et. al.*, 2006; Kelly-Hope and Thomson, 2008; Jancloes *et. al.*, 2014; Thomson *et. al.*, 2014;), among others (NASEM, 2016).

Although the sub-seasonal prediction method may not be the best option to detect short-term extreme events (e.g. floods), it could benefit sectors such as hydropower by predicting inflow volumes, and anomalous conditions within longer lead times, such as low flows and droughts (Dutra *et. al.*, 2014; Meibner *et. al.*, 2017). It could also be applied to draw the necessary adjustments between long-term and short-term planning, as new information is made available (for example, assumptions regarding the volume held in a reservoir), also delay or anticipated start of rainy/dry season.

Specifically, regarding the sub-seasonal time range, it is noticeable that there are few research projects concerned with the applications of numerical weather predictions within the sub-seasonal time range (up to 3 months, once called extended-range). Subsequently we discuss a few of the currently available works. White *et. al.*, (2017) reviews potential applications of sub-seasonal-to-seasonal (S2S) predictions, discussing new research and operational opportunities. It also outlines the key challenges for advancing this new frontier – identifying sources of predictability; improving forecasting skill; operationalization of predictions and communication with decision makers. Despite

being a review paper, it gives insights into the possibilities of applications and categorizing the primary challenges in this current, early stage of practices in S2S forecasting.

The study of Shah *et. al.*, (2017) is an application of sub-seasonal (of lead time up to day 45) precipitation forecasts, tailored to benefit the agricultural sector. The authors evaluated the meteorological prediction outputs from CFSv2, GEFSv2 and a local Indian Agency (IITM) against observations from the India Meteorological Department. The total runoff and the root-zone soil moisture was estimated using the Variable Infiltration Capacity (VIC) model, also applying bias correction methods on forecast variables. Their results show that the IITM products outperform the CFSv2 and GEFSv2 models; using the forcing variables from the IITM ensemble and the VIC model, they have predicted 45-day accumulated hydrologic variables with satisfying performance, in terms of correlation coefficient, Mean Absolute Error (MAE) and critical success index; providing useful information to water (such as total runoff) and agriculture (root-zone soil moisture and precipitation anomalies) managers.

The authors Monhart *et. al.*, (2019) compared the traditional ESP approach to a sub-seasonal (with a lead time up to day 32) hydrometeorological ensemble prediction system, within three catchments with distinct hydroclimatic conditions. They used ECMWF sub-seasonal temperature and precipitation inputs, with raw and bias corrected (pre-processed) datasets, aiming towards investigating the predictability of streamflow and the importance of the complex interactions between precipitation and temperature in a sub-seasonal timescale. The results, expressed in standard performance scores, including the Continuous Ranked Probability Skill Score (CPRSS), indicated that the sub-seasonal inputs showed improved predictability over ESP, specially at early lead times. Regarding skill in comparison with the ESP, they revealed that the raw forecasts only display improvement for the first 5 lead days, and pre-processing the precipitation improves it on early lead times. As for correcting the temperature, it enhances the skill on later lead times. One interesting aspect tested by the authors is the seasonal variation in skill, in this matter forecasts generally initiated in winter and spring show the highest benefits over the reference climatology. Furthermore, the research discusses some limitations of the quantile-mapping technique for distributed hydrological modelling (i.e. the variation inflation issue may be influenced by convective precipitation events, influencing all the results), it also provides insights in enhancing the generation of ESPs by suggesting that

only individual years be considered, possessing similar initial conditions. Another important conclusion is that solely pre-processing precipitation data is not enough to enhance the forecast performance, and it is by highlighting their combination with other variables (temperature) which improves the reliability, however, this verification went against a reference simulation as a replacement for real observations.

Regarding the testing of sub-seasonal forecasts, we could not find any that used quantitative precipitation forecasts, for application in tropical climates, for the evaluation of hydropower benefits, nor for South American locations. On the other hand, there is an increasing urge to systematically explore and evaluate the sub-seasonal forecasts across a wide range of activities and locations (Brunet *et. al.*, 2010; Vitart *et. al.*, 2012; Vitart *et. al.*, 2017; White *et. al.*, 2017).

The objective in this study is to perform one of the first evaluations of sub-seasonal hydrological forecasts applied to hydropower dams' locations in large tropical and sub-tropical basins, based on ECMWF QPFs which originated from the S2S project. The research is conducted within the Paraná River Basin, one of the most important hydropower producing regions in the South American continent. This study aims primarily to evaluate the ensemble streamflow through statistical scores, as well as comparing it to the well-established extended range prediction ESP technique, potentially providing information concerning the use of S2S data for hydrological modelling.

## 5.2. Study Catchment

The researched basin is the Paraná River Basin (PRB), located within Brazilian territory, covering regions from South-Central Brazil to the Itaipú hydropower dam. The PRB is one of the most important hydraulic systems in South America, being responsible for more than 50% of the hydroelectric production in the entire country (Adam *et. al.*, 2015). Contemplating around 150 large power generating reservoirs along its main river and tributaries – Paraná River, Grande, Tiete, Paranapanema and Iguaçu; ANEEL, 2008). These rivers also double as waterways for navigation, such as the Tietê-Paraná. The PRB has total area of approximately 907,000 km<sup>2</sup>, localized within coordinates 15.450 S to 26.850 S, 43.580 W to 56.110 W, as shown in figure 1.

The PRB concentrates approximately one third of the population of Brazil and covers several of the country federative units. Within the basin it is included the region with greater population and industrialization of Brazil. The main uses of water and its

conflicts are around public, industrial, agriculture and irrigation water supply, therefore, also suffers from the degradation of this resource in its main tributaries – originating from organic and inorganic pollution (mainly effluents).

The studied basin presents different hydrological regimes across its large territory, exhibiting a seasonality caused primarily by the action of air masses in Brazil. The region at the north end of the basin presents a tropical climate, with dry winters and more rain in the summer; the rainfall is tropical and convective. While the southern region presents steadier rainfall, evenly distributed throughout the seasons (Siqueira and Martins, 2018).

The coordination of the hydroelectric generation and transmission is under the responsibility of the National Electric System Operator (ONS), and usually uses medium-term average daily flow forecasts to perform the management of power generation (ONS, 2011, 2012a, 2012b, 2014), in which diverse methodologies are used, including hydrological modelling and forecasting.

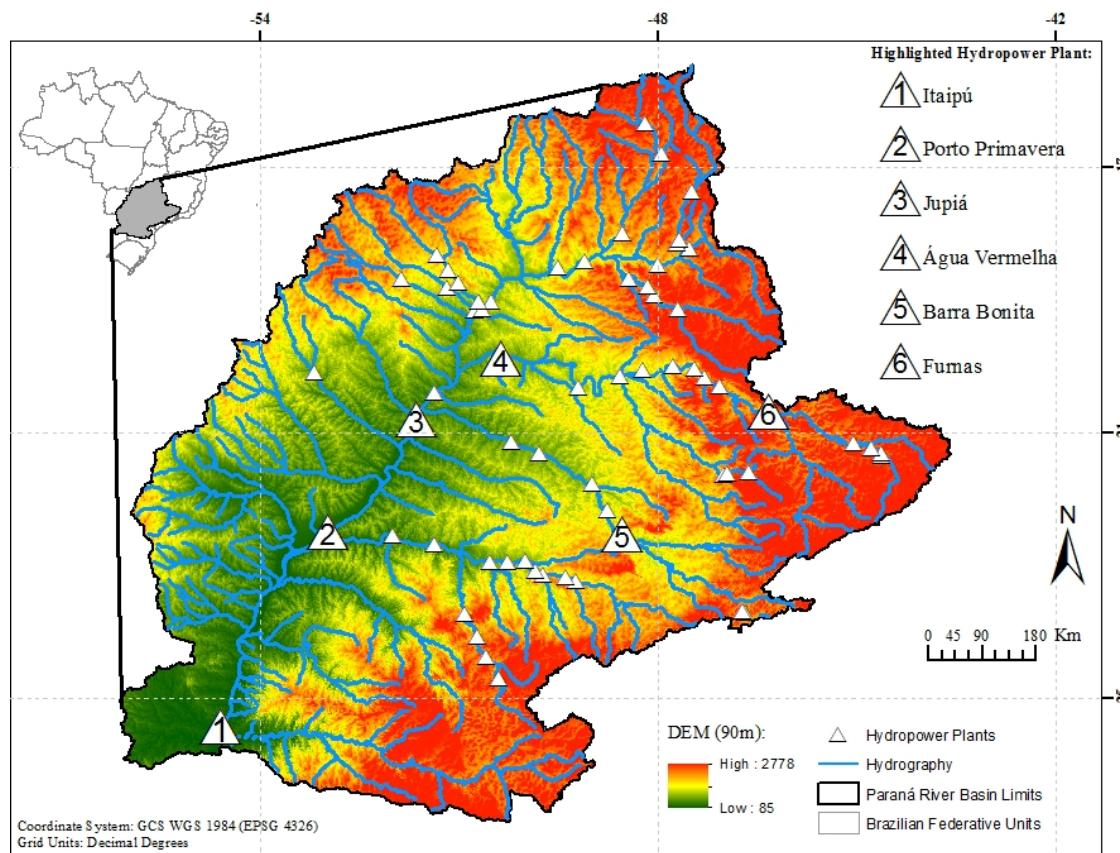


Figure 1. Location of the Paraná River Basin (PRB).

## **5.3. Methodology**

### **5.3.1. Precipitation Datasets**

The meteorological ensemble precipitation forecasts were provided by the ECMWF CY43R3 model, on a sub-seasonal time scale stemming from the S2S project (Vitart and Robertson, 2018), comprehending real-time forecasts for 2015 and 2016. It performs an integration of 51 ensemble members, including one unperturbed initial condition (control forecast) and 50 committed with small perturbations, running twice a week (Monday and Thursday, UTC 00) for up to 46 days. The data is freely available at: <https://apps.ecmwf.int/datasets/>. We used the forecast data with 0.125° grid resolution and daily accumulated time-steps (ECMWF, 2017b). We used the ECMWF forecasts due to its positive performance compared to other datasets (Buizza *et. al.* 2005; Tao *et. al.*, 2014). The ECMWF dataset was chosen as a result of Fan *et. al.*, (2015)'s study in the South American context, which analyzed medium-range forecasts originated from this research center for inflow verification and demonstrated the best performance of this ensemble among the inspected.

The observed precipitation dataset used to run the hydrological simulations was the Multi Source Weighted Ensemble Precipitation (MSWEP v2.1). This is a global dataset, covering the years from 1979 to 2016, with grid resolution of 0.1° and provided as 3-hourly accumulated value, which had to be accumulated from daily values (Beck *et. al.*, 2017a; Beck *et. al.*, 2017b). Employing a gridded dataset was the selected method in the current study due to its advantages over local in-situ gauges, as it uses complementary information from diverse sources such as satellite, reanalysis and data gauges; also providing information for long temporal availability without missing data.

### **5.3.2. Hydrological Model**

The MGB-IPH (described by Collischonn *et. al.*, 2007b) is a large-scale distributed model, used in several studies for hydrological simulations in South America (Tucci *et. al.*, 2003; Collischonn *et. al.*, 2005a, 2005b, 2007a; Paz *et. al.*, 2007; Getirana *et. al.*, 2010; Nóbrega *et. al.*, 2011; Meller *et. al.*, 2012; Paiva *et. al.*, 2013; Fan *et. al.*, 2014, 2015; Siqueira *et. al.*, 2016, 2018). In the Paraná River Basin, the model has been applied in Fan *et. al.*, (2012); Pontes *et. al.*, (2012, 2013); Adam *et. al.*, (2014, 2015); Collischonn *et. al.*, (2014); Colossi *et. al.*, (2017a, 2017b)'s studies.

The utilized version of this model discretizes the basin into unit catchments whenever there are confluences of streams or at specific points, these units are denominated mini-basins (Paiva *et. al.*, 2013). The soil and vegetation variability are classified by Hydrologic Response Units (HRU), whose parameters are associated with each HRU type (Kowen *et. al.*, 1993); for the evapotranspiration calculation, the model is based on Penman-Monteith (Shuttleworth, 1993); the surface runoff and soil water balance follow the Arno model approach (Todini, 1996); also, the streamflow routing is computed using the Muskingum-Cunge method (in the case of this study) or the full Saint-Venant when necessary (Paiva *et. al.*, 2013).

In this study, the basin was discretized into 1424 catchments, while the rainfall-runoff process was simulated using a daily time step. Model calibration was carried out using data from the National Electric System Operator (ONS), spanning the years between 1975 to 1995 for the calibration period and 1995 to 2010 for validation due to data availability and occurrences of extreme events Collischonn *et. al.*, (2014).

A comparison to the natural streamflow estimated by ONS, was conducted using the Nash-Sutcliffe (NS, Nash and Sutcliffe 1970) performance metrics, log-NS and volume error (dV). The metrics for the Hydropower Plants case study location is outlined in Table 1 for model calibration and validation periods. The NS is a measure of how the results of the model (MGB-IPH) are far preferable than an alternative, which in this case, is the value of average long range observed flows. The score spans values from  $-\infty$  to 1, among which the positive values indicate that the proposed model is better than the long range mean and values near zero suggest that the model's results are as undesirable as the long-range mean. The NS score tends to issue more importance to inflow spikes, thus using the flow logarithms (log-NS) is a way to obtain a less sensitive score to peaks and more sensitive to periods of flow recession. Finally, the relative volume error (dV) evaluates whether there is a systematic deviation from the overestimation or underestimation of the flow.

Table 2. Performance of MGB model on the study case gauges in the calibration and validation periods.

Location	Calibration (1975-1995)			Verification (1995-2010)		
	NS	log-NS	dV(%)	NS	log-NS	dV(%)
Água Vermelha	0,85	0,83	-10,10	0,85	0,88	-6,10
Barra Bonita	0,76	0,67	5,30	0,76	0,75	-6,50
Furnas	0,81	0,82	-9,90	0,84	0,87	-2,50
Itaipú	0,86	0,85	-2,80	0,85	0,85	-3,90
Jupiá	0,87	0,85	-3,50	0,87	0,88	-2,70
Porto Primavera	0,86	0,82	-3,60	0,88	0,87	-1,50

Based on Table 1, we believe that the hydrologic model calibration and verification was satisfactory for further hydrological applications since the NS and log-NS were above 0.75 and the volume error (dV) between  $\pm 10\%$ .

### 5.3.3. Data interpolation

Since the main river basin is discretized into 1424 unit catchments (elemental areas), the centroid coordinate of each of these was used to interpolate representative precipitation series from the gridded S2S data, by taking the nearest QPF grid pixel from the centroid coordinate as its value. The same interpolation had to be done for the MSWEP dataset.

### 5.3.4. Ensemble Streamflow Forecast

The experiments consisted of assembling a Hydrological Ensemble Prediction System (H-EPS), using the meteorological ensembles as forcing to the MGB-IPH model. Data is made available in real-time after a delay of 3 weeks, therefore it may not yet be available for real-time operations.

We also used the Extended Streamflow Prediction (ESP) technique to generate an ensemble of hydrologic simulations considering the historical rainfall data. Each ESP ensemble member considered the same period (day and month) of the real-time forecast lead-times, and a total of 20 years into the past was considered (i.e. number of climatological ensemble members). It is important to consider the need to derive an adequate initial condition for the hydrological model in each forecast, otherwise the errors associated with it would add up to the ESP bias (Arsenault and Cote, 2018). Although, we only resampled the historical rainfall data to proceed with the ESP.

We also used a reference forecast, a “perfect” rainfall forecast, in which one assumes the precipitation prediction to be equal to the observed. This reference forecast may be used to evaluate the model errors themselves, enabling, in the case of this study, for the assessment of forecasts having to consider only the uncertainties associated with the meteorological data.

Figure 2 shows examples of the result of ensemble streamflow forecast. The sub-seasonal ECMWF QPFs originated from the S2S database and the ESP series were used as input for generating the streamflow forecasts. The figure depicts a flood event on Itaipú location, on the upper figures the forecasts were issued two weeks prior a flow peak, and then on the bottom it shows the development of the event.

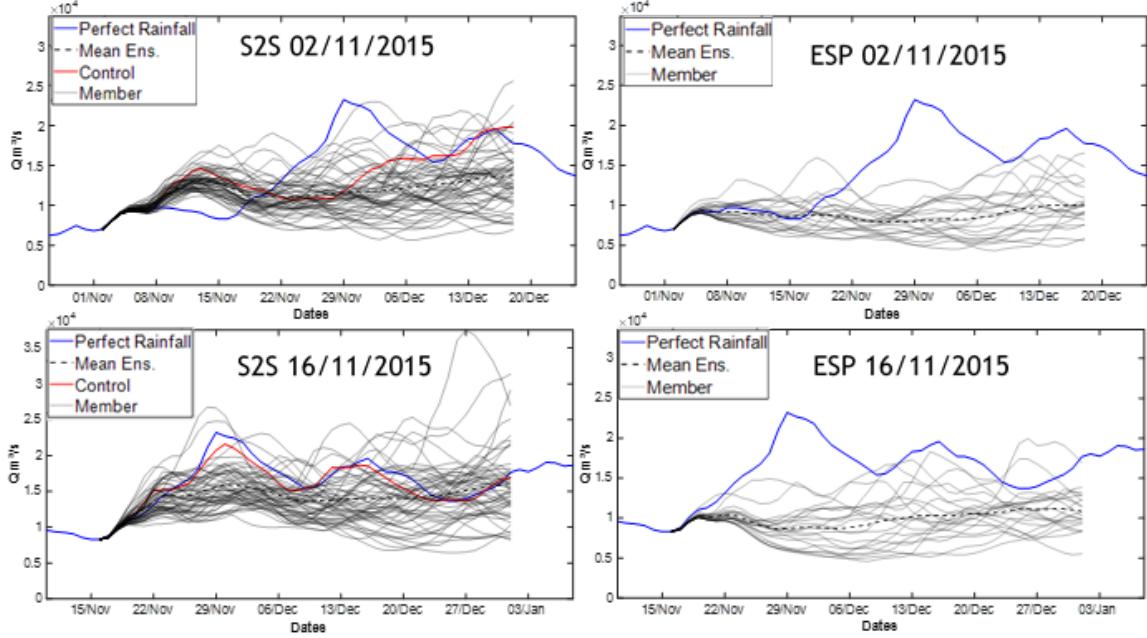


Figure 2. Visual analysis on sampled sub-seasonal streamflow forecasts at Itaipú HPP. It is noted that the S2S based forecasts followed in more accordance to the benchmark than the ESP based, providing more accurate information on inflows to the Itaipú dam location. On the left the S2S-based; on the right the ESP-based. Blue line refers to the streamflow benchmark, red line is the control member of the ensemble, gray line is an ensemble member and dashed black line is the ensemble mean.

### 5.3.5. Results Assessments

The hydrological simulations produced results in the streamflow series for all 1424 catchments, however, only the 6 case studies locations were assessed. One of the analyzed primary results is the comparison of the “perfect” rainfall simulation against the observed natural streamflow, provided by ONS, the Nash-Sutcliffe score was also computed at each location.

The ensemble forecasting was evaluated using the Ensemble Verification System (EVS) software, described by Brown *et. al.*, 2010. We applied some scores that are usual in ensemble forecasting, such as the Mean Absolute Error (MAE), Root Mean Squared Error (RMSE), Continuous Ranked Probability Skill Score (CRPSS) and Rank Histogram (Stanski et al., 1989; Hersbach, 2000; Wilks, 2006; Brown et al., 2010; Bradley and Schwartz, 2011; Jolliffe and Stephenson, 2012). These scores are usually employed in

ensemble assessments and are highly documented within specific statistical literature (Wilks, 2006; Brown et al., 2010; Jolliffe and Stephenson, 2012).

This assessment illustrates the performance of the ECMWF sub-seasonal forecasts in comparison with the climatological reference. We do not specify a threshold; hence all forecast streamflow values were issued. In this assessment, the objective was to present an overview of the reliability and performance of ensemble results, in comparison to the deterministic values given by the ensemble mean and ensemble control member – as these values may be representative of a deterministic forecast, it may be used in the absence of ensemble forecasts. The comparison with the ESP gives information on the performance of the ensemble against historical rainfall based forecasts.

The Mean Absolute Error (MAE) is a score that reduces the ensemble to its mean value for each time step, measuring the difference from the observed benchmark (i.e. “perfect” rainfall simulations). This score assigns the same weight to all errors and primarily measures the magnitude of the errors, the optimal value is equal to zero. Meanwhile, the Root Mean Squared Error (RMSE), as a quadratic score rule, it penalizes larger errors, providing a measurement on the variability of the errors’ magnitudes, serving as a measure of accuracy.

The Mean Continuous Ranked Probability Score (CRPS) summarizes the quality of the ensemble forecast reducing it to a single value, which is obtained by measuring the integrated square difference between the cumulative distribution function of the forecast value, and the corresponding function of the observed. The CRPS, when averaged for all pair of forecasts and observations, leads to the Mean CRPS, where lower values correspond to the optimal. It is important to highlight that the Mean CRPS may be used to compare the ensemble performance to a reference forecast, since it reduces to the MAE for deterministic forecasts. In addition, the Mean Continuous Ranked Probability Skill Score (CRPSS) measures the performance of the forecast system relative to another in terms of Mean CRPS.

In order to allow a comparison between different locations, errors scores (MAE and CRPS) were gathered after a normalization procedure. The calculated value of the respective scores were divided by the long-term average of the “perfect” rainfall simulated flow series of 2015 and 2016. Thusly, the result may disregard the magnitudes and express the errors relative to the mean flow.

The Rank Histogram (RH) is a measure of reliability (statistical consistency between, measurements and simulations, Hamill, 2000; Candille and Talagrand, 2005) and whether uncertainty is correctly represented in the forecast. It scopes out the fraction of observation that may fall between any two ranked ensemble members in the forecast distribution. This score is optimal (i.e. the forecast system is reliable in terms of Rank Histogram) when the probability of the observation falls between any two ranked members and is approximately uniform. A lack of spreading of the ensemble is indicated by a “U” shaped rank histogram (High probabilities in one or both tails), on the other hand an inverted “U” shape indicates an excessive spreading.

## 5.4. Results

### 5.4.1. Individual Assessments and Spread Analysis

Figure 3 displays the results of the MAE and CRPS metrics at each of the six dam locations for the ensemble mean and control forecast, after normalizing of the scores with the long-term average of each location.

The figure shows that the CRPS for the ensemble is always lower than MAE of the Ensemble Mean and the Control Member in all locations. The CRPS compared to the control forecast (deterministic reference) indicates better predictability from the ensemble mean. The MAE for the ensemble is always lower than the control member, and the errors readily increase from initial time steps onwards. It illustrates that for the Barra Bonita and Furnas locations, the errors are more prominent in relation to the long-term average.

In general, for the Itaipú (827,000 km<sup>2</sup>), Porto Primavera (574,000 km<sup>2</sup>), Jupiá (479,000 km<sup>2</sup>) and Água Vermelha (139,000 km<sup>2</sup>) locations, the three first being located along the Paraná River (the main river of the basin), and the forth on the tributary Grande river, the MAE and CRPS magnitudes for the ensemble are placed around 0.20 and 0.15 times the long term flow average. As for the control member, until day 8 the MAE value was akin to the ensemble, and after this lead time, the values were around 0.3 times the long-term average.

The Furnas (52,000 km<sup>2</sup>) location, situated on the Rio Grande river, and the smallest drainage area of all locations in the ensemble, presented a MAE with values around 0.3 times the long-term average, and 0.2 times for the CRPS. Regarding the control member,

the MAE resulted in values ranging 0.5 times, and, aside from that, around day 6 it showed disparity with the ensemble.

The Barra Bonita ( $33,000 \text{ km}^2$ ) location, situated on the Tietê river, presented the greatest variability of MAE and CPRS, ranging values around 0.6 times the long-term average for the first score and 0.4 times for the second, within the ensemble. The control member presented MAE values over 0.8 times, and until day 8 the score remained close to ensemble.

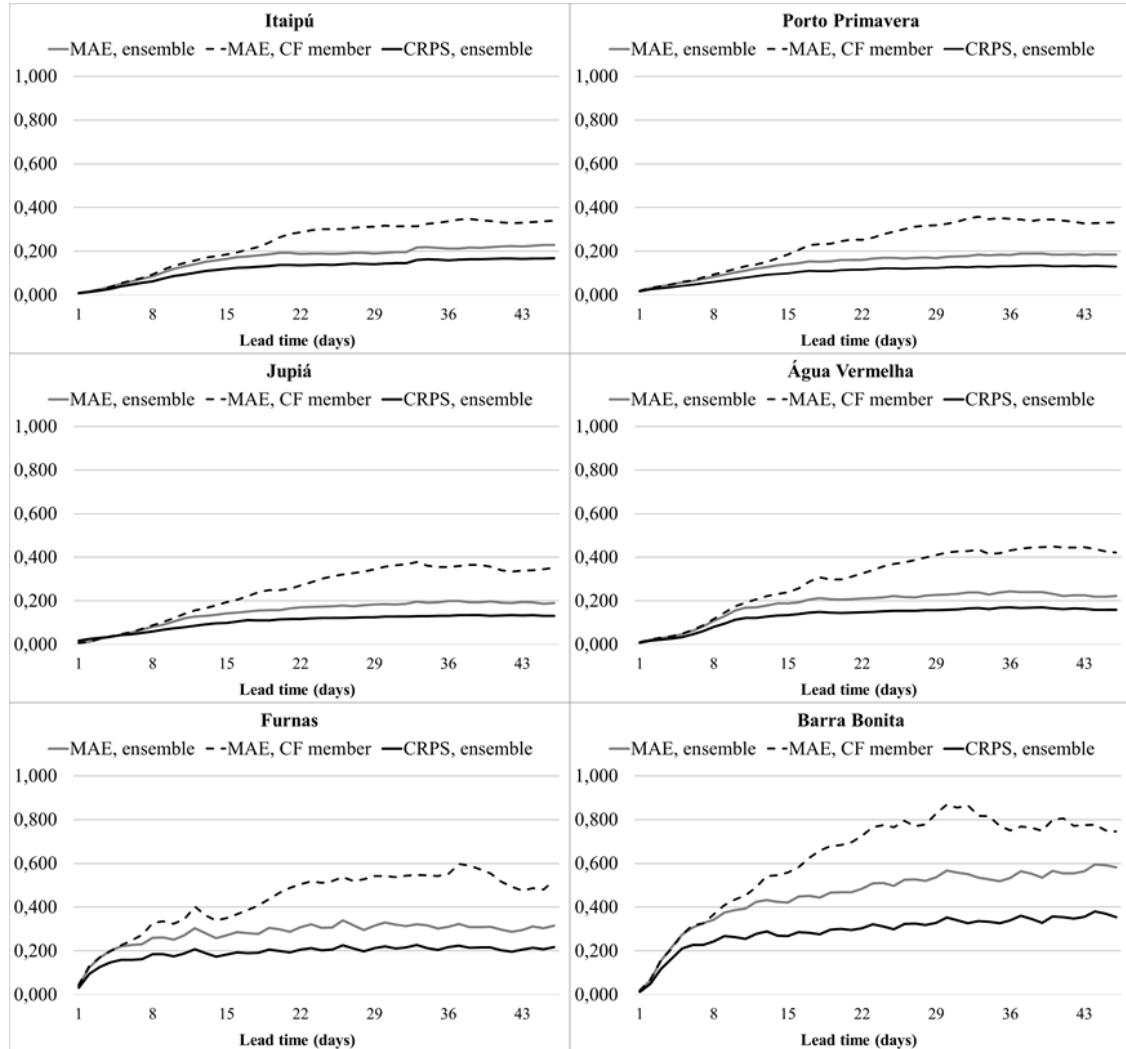


Figure 3. Evolution on the lead time up to 46 days of the MAE, RMSE and CRPS for the forecasts issued.

Figure 4 shows the normalized Root Mean Squared Error (RMSE) of the ensemble mean on all locations. In the figure it is indicated that the errors tend to increase as the drainage area decreases. The three locations situated along the main river (Itaipú, Porto Primavera and Jupiá) presented the smallest RMSE relative to the long-term average. As for the ones located on the tributary Grande River (Água Vermelha and Furnas), this

behavior appears once more, in addition, for Furnas the errors increase promptly from initial time steps. Finally, in the Barra Bonita location, which represents the smallest drainage area, located on tributary Tietê River, it presented the largest normalized RMSE as well.

In general, the locations with larger drainage areas performed better, and it is duly noted that the hydrological forecasts in locations with a drainage area above 479,000 km<sup>2</sup> the RMSE score does not present significant improvements, suggesting that this value may be an area threshold in which the performance of hydrological forecast results cannot be enhanced.

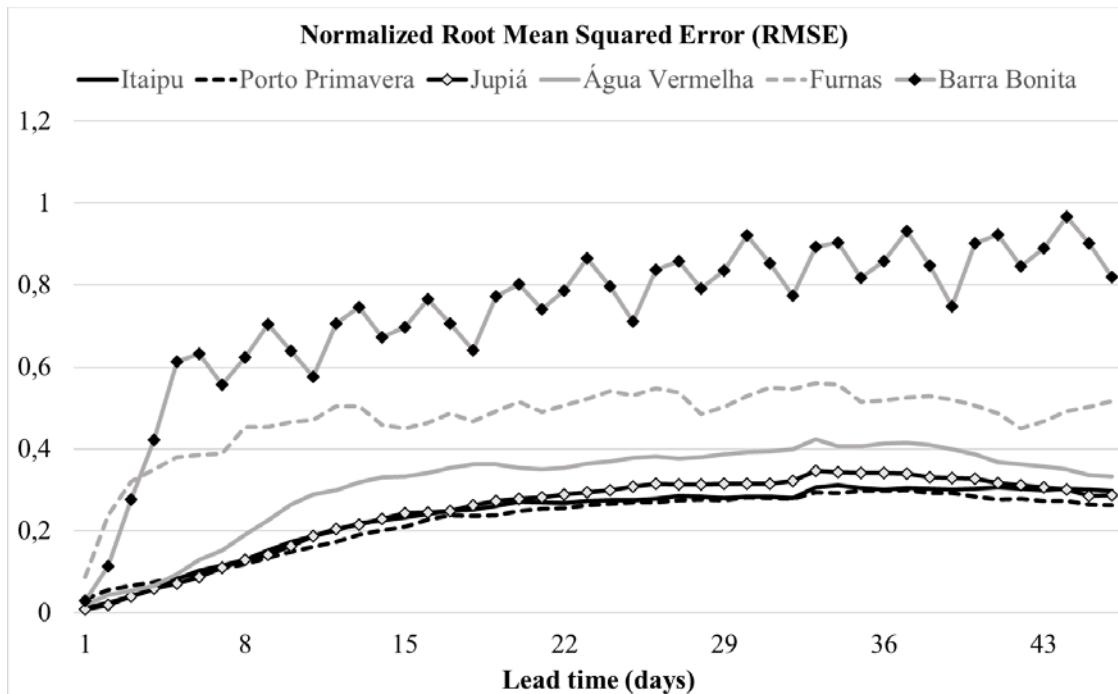


Figure 4. Normalized RMSE on all locations, figure shows that the error tends to increase as the drainage area of the location decreases.

Figure 5, 6 and 7 show the 51-member rank histogram for Itaipú, Furnas and Barra Bonita dam locations, at sampled lead times 1, 15, 20 and 46, showing the rank histogram's behavior throughout the forecast horizon. From Itaipú location, the general behavior of the ensemble spread is demonstrated, which is similar to that of the other dam localities over the locations along the Paraná River (Porto Primavera and Jupiá), as well as the Água Vermelha location.

The Itaipú rank histograms indicate that in early lead-times, approximately from day 1 up until day 15, there is a lack of spread, represented by the “U” shape of the histograms, and as the forecast lead times increase, more spread is presented (in the flat form of the histograms). These results are compatible with ensemble forecasts, in which

the lack of spread in early lead-times is noted as the only uncertainty considered is the precipitation (Fan *et. al.*, 2014).

For the Furnas rank histograms, the lack of spread on early lead times and a small tendency towards an overestimation of the forecast streamflow over the entire horizon is also perceived. The Barra Bonita rank histograms show that in early timesteps there is a lack of spread (“U” shape), but along with lead time evolution a tendency to overestimate the streamflow is noted (positive bias).

## Itaipú

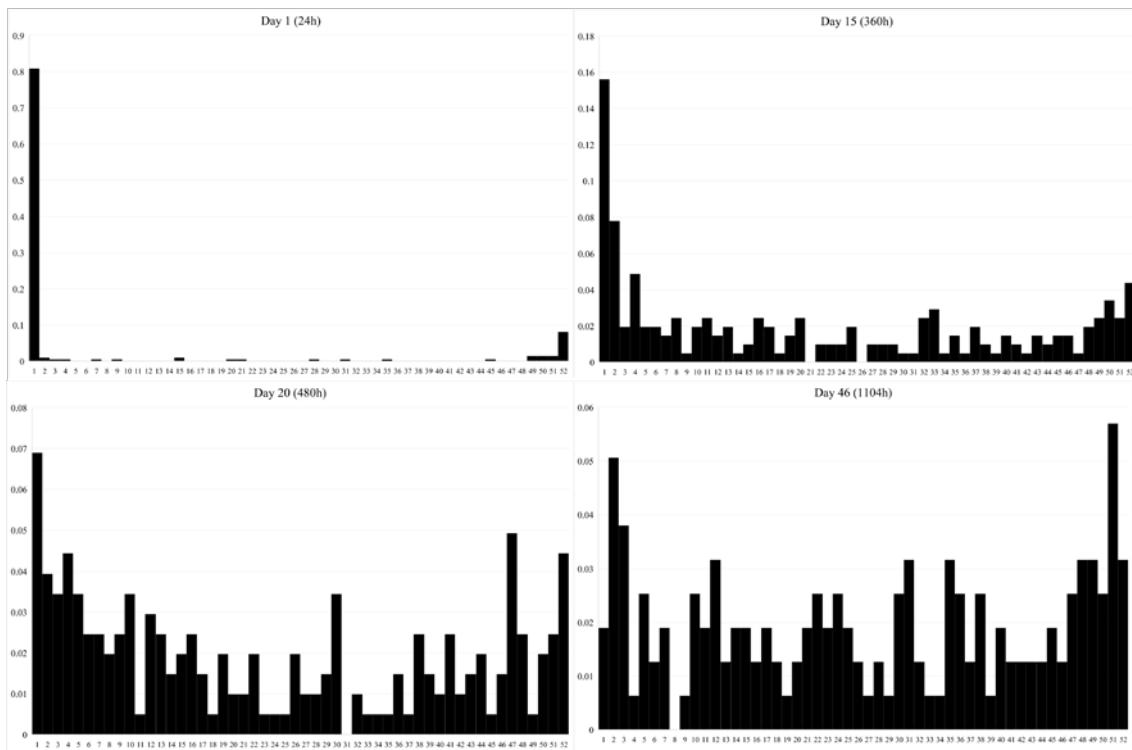


Figure 5. Rank Histograms indicating a lack of spread in early lead times. This behavior it is akin to the other locations along the main river of the basin (Paraná River) – Porto Primavera, Jupiá and Água Vermelha.

## Furnas

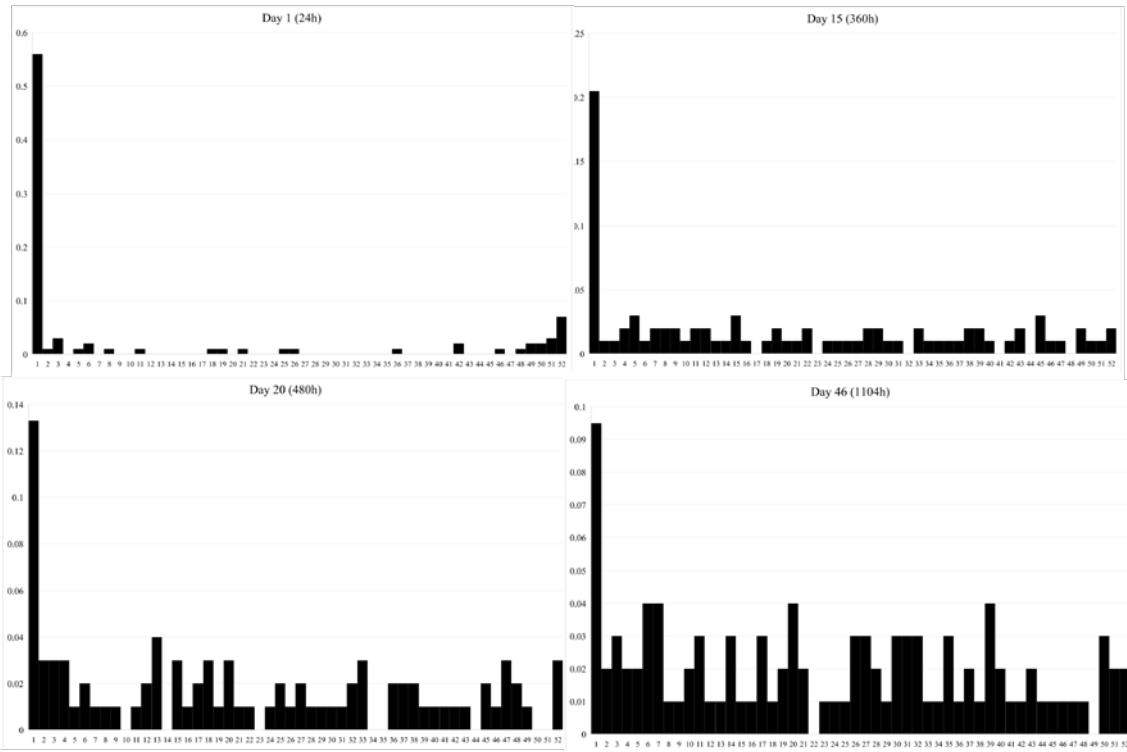


Figure 6 Rank Histograms indicating right from initial time step, a tendency towards overestimation on the forecast streamflow.

## Barra Bonita

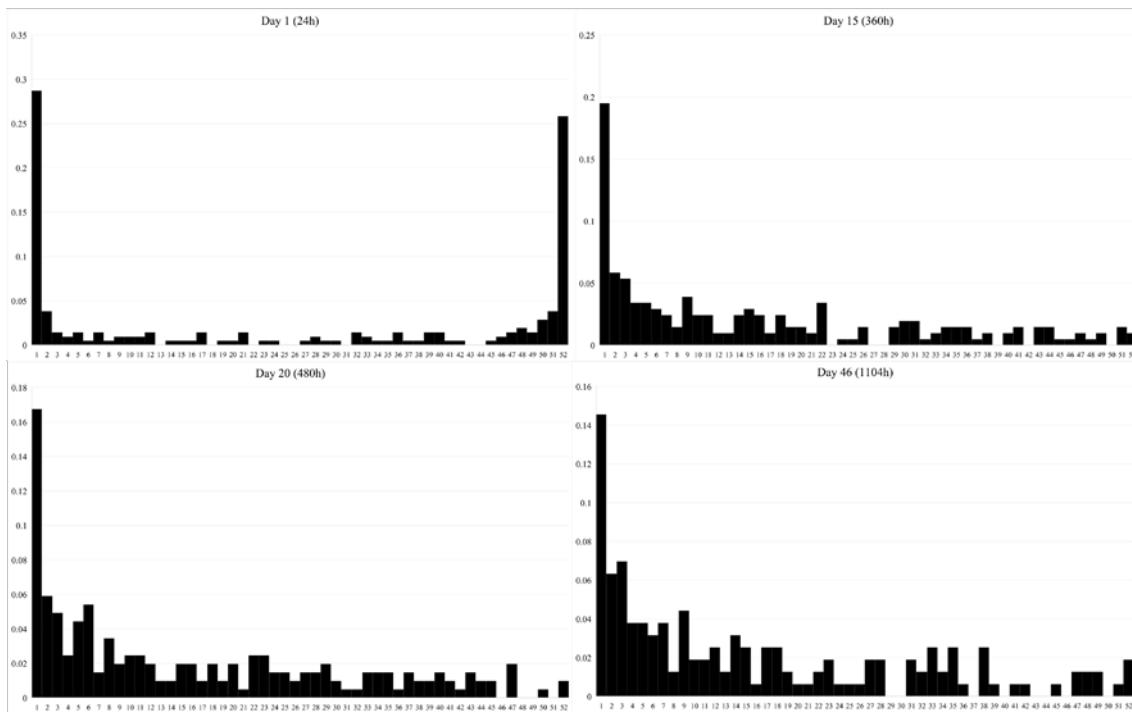


Figure 7. Rank Histograms indicating lack of spread in early lead times, but a tendency to overestimation (positive bias) along the development of the forecast.

#### **5.4.2. Skill Against Reference Forecast**

Figure 8 shows the CPRSS results for the six dam locations, delineating the performance of the sub-seasonal streamflow forecast in comparison to the ESP, based on historical rainfall data (reference forecast). As the CPRSS perfect score is 1, indicating a higher performance skill of S2S based forecasts, and negative values indicating that the reference forecast performs better in terms of CPRS.

This result shows that for the Itaipú location, up until day 3 the reference ESP forecast outperforms the sub seasonal ensemble. At the Porto Primavera, Jupiá and Água Vermelha locations, the score presents similar behavior, in which only after day 3 did the sub seasonal ensemble outperform the reference forecast; however, it is verified that approximately after a month (day 30) the ESP performs superior skill. Broadly, these results concur with studies investigating the quality of ESP, which claims that many ensemble predictions systems have difficulties in outperforming ESP after a month of forecasting (Arnal *et. al.*, 2018; Lucatero *et. al.*, 2018; Monhart *et. al.*, 2019). As for the deficient sub-seasonal ensemble skill until day 3, this is possibly caused by the good ESP skill on forecasting the initial lead-days on large basin, in which the inertial memory of hydrological conditions has more influence on the prediction.

The Barra Bonita location presented a better skill of the sub-seasonal ensemble across all time steps. Finally, in Furnas, the sub-seasonal forecasts were slightly better than the ESP until the third week (day 21).

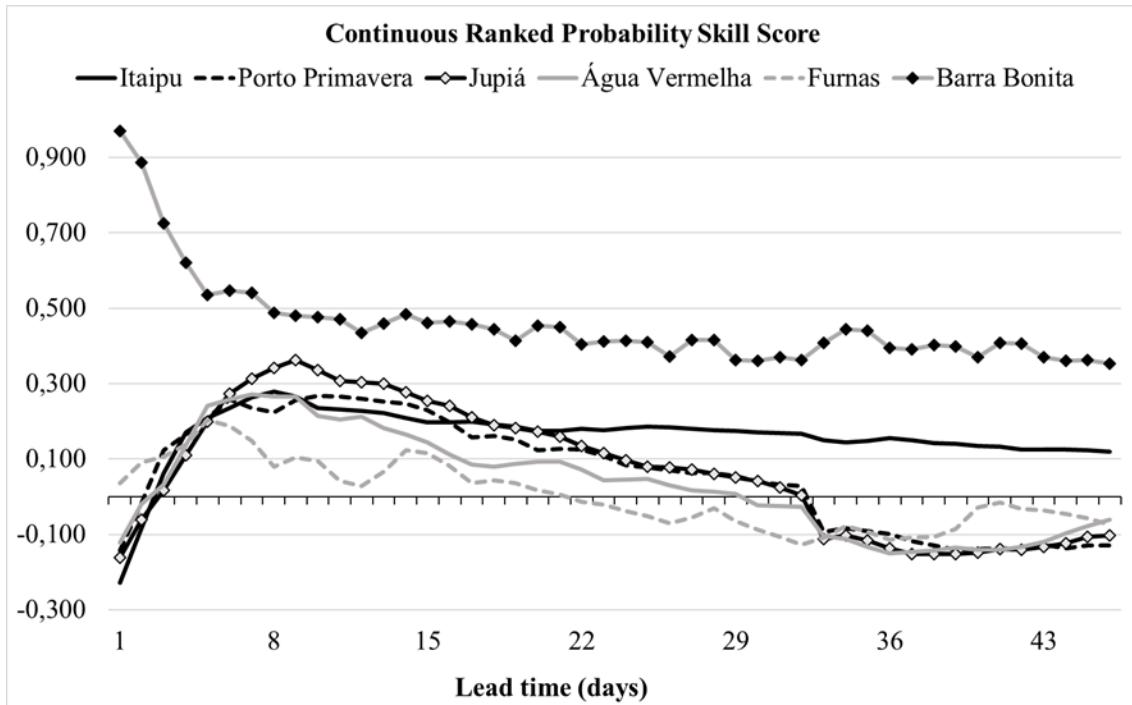


Figure 8. Mean Continuous ranked probability skill score (CPRS) for the sub seasonal based forecasts against ESP as reference.

### 5.5. Discussion

The results from the statistical verification indicates that ensemble hydrological forecasting presents many advantages when compared to comparison to the deterministic (control member), in terms of MAE and CPRS. After a week of lead time, the direct errors of the ensemble are always lower than the deterministic reference, for all six locations. Also, it is suggested that the error scores may be dependent on the basin scale, since smaller basins presented greater amounts of errors (Barra Bonita and Furnas), as it may be attenuated by the streamflow generation processes on larger basins.

Meteorologically, larger drainage areas performed better possibly due to errors related to the spatial resolution of the meteorological input being averaged for greater area values. Consequently, on larger basins the errors tend to compensate for themselves. Another aspect to consider, in a large basin as Paraná River basin, there is different precipitation systems acting within the basin regions and therefore it may present more predictability or forecast skill on some of the regions. On the hydrological model, larger areas result in better performance in the simulations, given that errors on parametrization and discretization are also compensated as well. Remarkable is the fact that for drainage areas equal or greater than 479,000 km<sup>2</sup> (Jipiá, P. Primavera and Itaipu Dam), RMSEs of

hydrological forecasting were very similar, suggesting a threshold area for bearing the best results.

Regarding Rank Histograms, the statistical metrics showed that for the early lead times, results are more dependent on the initial observed conditions in the basin rather than on meteorological inputs, as indicated by the lack of spread in the ensemble across all locations. The locations along the Paraná River and the Água Vermelha location, show an increased reliability along with further lead times. On Barra Bonita, despite a lack of spread on initial lead times, a positive bias is noted along the forecast. Furthermore, Furnas presented a lack of spread on early lead times and a small tendency to positive bias – indicating a systematic overestimation of the streamflow on these two last locations, suggesting that some bias removal technique may be applied.

The CPRSS results suggest that the S2S based forecast have more skill than the ESP based, therefore, it may provide more valuable information on decision making processes than the forecasts that relies on historical series. The inflow estimation and reservoir management may benefit from the modelled framework used on this study, once we highlighted the associated errors within the forecast horizon and provided estimates of streamflow several weeks ahead.

Another important aspect investigated is the rainfall seasonality effect on the ESP performance, one may note that on Barra Bonita location is within a climate region that presents little seasonality, therefore, resampling historic rainfall from distinct years toward the past may not be representative of future conditions.

The results suggest that the ECMWF ensemble may perform differently at distinct sub-basins among the study area. It can be noted specially for the locations that aren't along the main river of the studied basin, that the performance results on one location may not be transposed to another. This evidence is also perceived within the studies of Fan *et. al.*, (2015) that tested ensemble forecasts on distinct watersheds within same hydroclimatic region.

The climatic characteristic at each location may influence the performance on techniques that rely on historical series, that is, in cases where is presented little seasonality, using the S2S based QPF have better skill, as it considers more accurate meteorological conditions along forecast lead time.

The lack of spread on early lead times could be improved by applying a data assimilation method and by considering the uncertainties in initial hydrological conditions. Also, we did not carry out any post-processing on the forecast streamflow, which could be assessed in future studies, considering each location's particularities. For an operational application of the S2S forecasts, it may be necessary to account not only for the meteorological uncertainties. This matter may be resolved by adopting the aforementioned strategies. Moreover, as the interpretation of the ensemble is not entirely straight-forward, a better understanding would be attained through the use of optimization models.

Our work brings light to the sub seasonal hydrological forecast, in one of the most important hydrographic regions of South America, the Paraná River Basin. These forecasts have been shown to provide medium-to-long term valuable information, especially for inflow assumptions in hydroelectric power plants, and have outperformed the traditional ESP approach. Also, the results are in agreement with other studies that have evaluated the performance of ensemble forecasts in relation to deterministic reference, which generally confer the best quality of forecast to the ensemble.

## 5.6. Conclusion

This research presented one of the first statistical assessments of the sub-seasonal to seasonal (S2S) meteorological data as input for hydrological modelling in a tropical and sub-tropical context, considering the location of hydropower plants which could potentially benefit over the streamflow predictions.

The results showed that the performance of the issued ensemble forecasts possess some advantages in applications where total inflows is necessary when compared to the deterministic (control member) and to a climatological reference (ESP).

The locations with greater drainage area situated along the main river of the basin presented the best performance, when taking into account MAE, CPRS, and CPRSS, especially for the Itaipú dam, which presented a higher skill than climatology after day 3 until the end of the forecast horizon. Following the Paraná River upstream, the direct errors (MAE and CPRS) presented slight deteriorations, concerning the skill score the results indicated similar behavior to Itaipú, except that after a month of lead time, it has underperformed the historical reference.

The two other locations, situated in a tributary of the main river, with smaller drainage areas, presented a higher degree of divergence in the results. On Barra Bonita and Furnas, the MAE and CPRS resulted on the largest values, possibly caused by the bias. On the other hand, the first location outperformed the ESP on all timesteps; and the second presented skill above the ESP until week 3 (day 21). Ultimately, we expect that our results will contribute to the usage of sub-seasonal horizon forecasts, and its benefits to hydrological forecasting, consolidating ensemble forecasting experiments in large South American basins as well. For hydropower generation purposes in large-scale basins, the sub-seasonal streamflow predictions proved to be promising, with better skill than the forecasts generated using the historical rainfall. In addition, the efforts addressed some issues related to the main incitements of the sub-seasonal to the seasonal (S2S) project (Vitart *et. al.*, 2017).

Regarding future works, we believe that more test cases may be useful, considering the meteorological inputs originated from different research centers, as they are freely available from the S2S database – potentially providing a ‘grand’ ensemble with more statistically reliable results. Likewise, succeeding recent efforts in the integrated modeling of complex hydraulic systems in South America (e.g. Siqueira *et. al.*, 2018), it is expected that value can be extracted from these models towards the use of sub-seasonal forecasting (precipitation and other variables) in hydrological forecasts, especially when regarding techniques that only employ historical information.

## 6. Conclusão

A previsão de variáveis hidrológicas, como a precipitação e a vazão em recursos hídricos, feita em prazo de antecedência sub sazonal, possui valor e utilidade em diversas aplicações, apesar das incertezas associadas a este horizonte. Ainda, nota-se que o benefício potencial destas previsões está vinculado ao uso final, isto é, deve-se adequar o produto (previsão) à aplicação desejada.

Ao longo desta dissertação foram estudados aspectos sobre a utilização de previsões numéricas de precipitação por conjunto em horizonte sub sazonal, na modelagem de vazões. No capítulo 4, foram exploradas algumas questões relativas às previsões quantitativas de precipitação por conjunto, no qual pode-se estimar erros associados aos dados da base de dados S2S para a Bacia do Rio Paraná, por meio de métricas como o erro médio absoluto (MAE), raiz quadrada do erro médio (RMSE) e *brier score* (BS).

Além disso, testou-se a eficácia de dois métodos de correção de erros sistemáticos, os quais não obtiveram melhorias em nenhuma das métricas estatísticas (MAE, RMSE e BS). Todavia, pode-se constatar que ambos os métodos testados introduziram variabilidade na climatologia intra-anual da precipitação. Estes resultados podem ajudar nas estimativas de períodos mais secos e outros com maiores volumes de chuvas.

A respeito destas avaliações, recomenda-se para trabalhos futuros, a avaliação estatística em regiões distintas dentro da bacia e outras metodologias mais robustas de correção de erros sistemáticos, por exemplo, a correção da fração de dias secos na climatologia intra-anual.

O desenvolvimento de um Sistema de Previsão Hidrológica por Conjunto (*H-EPS*, em inglês), aplicando os dados de precipitação S2S ao modelo MGB-IPH, foi apresentado no capítulo 5. A partir de múltiplas simulações de vazões, foi avaliado o desempenho do conjunto (*ensemble*), em termos de erro médio absoluto, ao longo do horizonte sub sazonal.

Também, pode-se inferir sobre as tendências de espalhamento do conjunto, por meio dos *Rank Histograms*, nos quais percebeu-se que nas duas localidades situadas fora do rio principal da bacia houve tendência de superestimativas das vazões. Por fim, constatou-se o benefício da qualidade (*skill*) da previsão S2S em relação à tradicional técnica ESP, que em geral, superou a primeira apenas após 30 dias da previsão em quase todas as localidades testadas.

Sobre os aspectos abordados neste capítulo, recomenda-se para trabalhos futuros, o aumento na complexidade do *H-EPS*, incluindo metodologias de assimilação de dados e pós-processamento nas saídas das previsões vazão por conjunto. Outro ponto passível de ser explorado é o aproveitamento dos dados gerados em outros centros de pesquisas meteorológicas, disponíveis gratuitamente na base S2S – de modo que se realize um *grand ensemble*, obtendo maior confiabilidade estatística.

As questões abordadas nesta dissertação vão ao encontro com àquelas colocadas na agenda de pesquisa descrita em WMO (2018), e assim, baseado no exposto anteriormente espera-se que tenha contribuído à ciência da previsão hidrológica de uma forma geral. Foram expostas algumas potencialidades, deficiências e benefícios da previsão em horizonte sub sazonal - e embora a pesquisa ainda esteja em estágios incipientes na América do Sul, acredita-se que nos próximos anos, a qualidade das previsões numéricas

sub sazonais tendem a crescer, em vista de novas tecnologias de monitoramento e o engajamento da comunidade científica (e operacional) a respeito desta temática.

## 7. Referências

- (ANEEL). Agência Nacional de Energia Elétrica. (2008). Atlas de energia elétrica do Brasil. Brasília: ANEEL.
- ADAM, K. N. ; FAN, F. M. ; PONTES, P. R. M. ; BRAVO, J. M. ; COLLISCHONN, W. (2015). Mudanças climáticas e vazões extremas na Bacia do Rio Paraná / Climate Change and Extreme Streamflows in Paraná River Basin. Revista Brasileira de Recursos Hídricos, v. 20, p. 999-1007, 2015
- ADAM, K. N.; FAN, F. M. ; PONTES, P. R. M. ; BRAVO, J. M. ; COLLISCHONN, W. (2014) . Climate Change and Floods in Paraná River Basin. In: 6th International Conference on Flood Management - ICFM6, 2014, São Paulo - SP. PROCEEDING OF THE 6th International Conference on Flood Management - ICFM6. Porto Alegre - RS: ABRH, 2014. p. PAP014788.
- ANGHILERI, D., N. VOISIN, A. CASTELLETTI, F. PIANOSI, B. NIJSSEN, ANDD. P. LETTENMAIER (2016), Value of long-term streamflow forecasts to reservoir operations for water supplyin snow-dominated river catchments, Water Resour. Res., 52, 4209–4225, doi:10.1002/2015WR017864
- ALLASIA, D. G. (2007). “Avaliação da previsão hidro-climática no Alto Paraguai”. Tese de doutorado, Universidade Federal do Rio Grande do Sul, Instituto de Pesquisas Hidráulicas, Porto Alegre, Brasil, 208 p.
- ARNAL, L., CLOKE, H. L., STEPHENS, E., WETTERHALL, F., PRUDHOMME, C., NEUMANN, J., KRZEMINSKI, B., PAPPENBERGER, F. (2018). Skilful seasonal forecasts of streamflow over Europe? Hydrology and Earth System Sciences, 2057-2072.
- BALDWIN, M. P., STEPHENSON, D. B., & THOMPSON, D. W. (2003). Stratospheric Memory and Skill of Extended-Range Weather Forecasts. SCIENCE, 636-640.
- Bárdossy, A., & Pegram, G. (2011). Downscaling precipitation using regional climate models and circulation patterns toward hydrology. WATER RESOURCES RESEARCH, 1-18.
- BARTHOLMES, J., & TODINI, E. (2005). Coupling meteorological and hydrological models for flood forecasting. Hydrol. Earth Syst. Sci., 9, 333-346. <https://doi.org/10.5194/hess-9-333-2005>
- BECK, H. E., MING PAN, TIRTHANKAR ROY, GRAHAM P. WEEDON, FLORIAN PAPPENBERGER, ALBERT I. J. M. VAN DIJK, GEORGE J. HUFFMAN, ROBERT F. ADLER, AND ERIC F. WOOD. (2019). Daily evaluation of 26 precipitation datasets using Stage-IV gauge-radar data for the CONUS. Hydrol. Earth Syst. Sci., 23, 207–224, <https://doi.org/10.5194/hess-23-207-2019>
- BECK, H. E., VERGOPOLAN, N., PAN, M., LEVIZZANI, V., DIJK, A. I., & WEEDON, G. P. (2017). Global-scale evaluation of 22 precipitation datasets using gauge observations and hydrological modeling. Hydrology and Earth System Science, 6201-6217.
- BECK, H. E. WOOD, M. PAN, C. FISHER, D. MIRALLES, A. VAN DIJK, T. MCVICAR, AND R. ADLER, (2018): MSWEP V2 global 3-hourly 0.1° precipitation: methodology and quantitative assessment. Bull. Amer. Meteor. Soc. doi:10.1175/BAMS-D-17-0138.1, in press.
- BELL, V. A., DAVIES, H. N., KAY, A. L., BROOKSHAW, A., & SCAIFE, A. A. (2017). A national-scale seasonal hydrological forecast system: development and evaluation over Britain. Hydrol. Earth Syst. Sci., 21, 4681-4691. <https://doi.org/10.5194/hess-21-4681-2017>
- BERG, P., FELDMANN, H., & PANITZ, H.-J. (2012). Bias correction of high resolution regional climate model data. Journal of Hydrology, 80-92.
- BOÉ, J., TERRAY, L., HABETS, F., & MARTIN, E. (2007). Statistical and dynamical downscaling of the Seine basin climate for hydro-meteorological studies. INTERNATIONAL JOURNAL OF CLIMATOLOGY, 1643–1655.
- BOUCHER, M.-A.; TREMBLAY, D.; DELORME, L.; PERREAU, L.; ANCTIL, F. (2012). “Hydroeconomic assessment of hydrological forecasting systems”. J. Hydrol., v. 416 417, np. 133–144, 2012

- BRAMAN, L. M., AALST, M. K., MASON, S. J., SUAREZ, P., AIT-CHELLOUCHE, Y., & TALL, A. (2012). Climate forecasts in disaster management: Red Cross flood operations in West Africa, 2008. *Disasters*, 144-164.
- BRAVO, J. M. (2006). "Otimização da operação de um reservatório para controle de cheias com base na previsão de vazão". Porto Alegre: UFRGS. Dissertação de mestrado em Recursos Hídricos e Saneamento Ambiental, Instituto de Pesquisas Hidráulicas, Universidade Federal do Rio Grande do Sul. 155p,
- BRAVO, J. M.; COLLISCHONN, W.; PILAR, J. V.; TUCCI, C. E. M. (2008). "Otimização de regras de operação de reservatórios com incorporação da previsão de vazão". *Revista Brasileira de Recursos Hídricos*, v. 13(1), p. 181-196.
- BRAVO, J.; PAZ, A.; COLLISCHONN, W.; UVÖ, C.; PEDROLLO, O.; CHOU, S. (2009). "Incorporating Forecast of Rainfall in Two Hydrologic Models Used for Medium-Range Streamflow Forecasting". *Journal of Hydrologic Engineering*, v. 1, n. 5, p. 435-445.
- BREUER, N. E., FRAISSE, C. W., & CABRERA, V. E. (2010). The Cooperative Extension Service as a Boundary Organization for Diffusion of Climate Forecasts: A 5-Year Study. *Journal of Extension*, 1-5.
- BRUNET, G., SHAPIRO, M., HOSKINS, B., MONCRIEFF, M., DOLE, R., KILADIS, G. N., KIRTMAN, B., LORENC, A., MILLS, B., MORSS, R., POLAVARAPU, S., ROGERS, D., SCHAAKE, J., SHUKLA, J. S. (2010). Collaboration of the weather and climate communities to advance subseasonal-to-seasonal prediction. American Meteorological Society, 1397-1406.
- BUIZZA, R. (1997). "Potential forecast skill of ensemble prediction and spread and skill distributions of the ECMWF Ensemble Prediction System". *Monthly Weather Review*, v. 125, p. 99-119.
- BUIZZA, R., HOLLINGSWORTH, A., LALAURETTE, F., & GHELLI, A. (1999a). Probabilistic Predictions of Precipitation Using the ECMWF Ensemble Prediction System. *Weather and Forecasting*, 14, 168–189. [https://doi.org/10.1175/1520-0434\(1999\)014<0168:PPOPUT>2.0.CO;2](https://doi.org/10.1175/1520-0434(1999)014<0168:PPOPUT>2.0.CO;2).
- BUIZZA, R., MILLER, M., & PALMER, N. (1999b). Stochastic representation of model uncertainties in the ECMWF Ensemble Prediction System. *Quarterly Journal of the Royal Meteorological Society*, 2887-2908.
- BUIZZA, R. (2008). The value of probabilistic prediction. *Atmospheric Science Letters*, 36-42.
- BUIZZA, R.; LEUTBECHER, M.; ISAKSEN, L. (2008). "Potential use of an ensemble of analyses in the ECMWF Ensemble Prediction System". *Quart. J. Roy. Meteor. Soc*, 134, 2051-2066, doi: 10.1002/qj.346.
- BUIZZA, R., & LEUTBECHER, M. (2015). The forecast skill horizon. *Quarterly Journal of the Royal Meteorological Society*, 3366-3382.
- BUONTEMPO, C., HEWITT, C. D., DOBLAS-REYES, F. J., & DESSAI, S. (2014). Climate service development, delivery and use in Europe at monthly to inter-annual timescales. *Climate Risk Management*, 1-5.
- CALHEIROS, A. J. P.; ENORÉ, D. P.; MATTOS, E. V.; COSTA, I. C. C.; MACHADO, L. A. T. (2016). "Sistema de Previsão Imediata: Descrição dos Produtos". Instituto Nacional de Pesquisas Espaciais – INPE. São José dos Campos – SP.
- CANNON, A. J., SOBIE, S. R., & MURDOCK, T. Q. (2015). Bias Correction of GCM Precipitation by Quantile Mapping: How Well Do Methods Preserve Changes in Quantiles and Extremes? *JOURNAL OF CLIMATE*, 6938 6959.
- CARVALHO F.; SILVA, D. A.; SANTOS, J. P. L.; LIMA, V. C.G.R. (2005). "Aplicação de redes neurais artificiais na previsão de precipitação na bacia do rio Mundaú – Alagoas". In: Simpósio Brasileiro de Recursos Hídricos, 16, João Pessoa – PA. Anais 1 CD.
- CHAI, T., & DRAXLER, R. R. (2014). Root mean square error (RMSE) or mean absolute error (MAE)? – Arguments against avoiding RMSE in the literature. *Geoscientific Model Development*, 1247-1250.
- CHANGNON, S. A.; VONNAHME, D. R. (2003). "Impact of spring 2000 drought forecast on Midwestern water management". *Journal of Water Resources Planning and Management*, v129(1), p. 18-25.
- CHIEW, F. H. S.; ZHOU, S. L.; MCMAHON, T. A. (2003). "Use of seasonal streamflow forecasts in water resources management". *Journal of Hydrology*, 270, p. 135-144.
- CHOU S. C.; NUNES, A. M. B.; CAVALCANTI, I. F. A. (2000). "Extended range forecasts over South America using the regional ETA model. *Journal of Geophysics Research*, Vol. 105, n. 8, p. 10147-10160

- CLOKE, H. L., & PAPPENBERGER, F. (2009). Ensemble flood forecasting: A review. *Journal of Hydrology*, Volume 375, Issues 3–4, 15 September, Pages 613-626. 2009. <https://doi.org/10.1016/j.jhydrol.2009.06.005>
- CLOKE, H. A., PAPPENBERGER, F., VAN ANDEL, S. J., SCHAAKE, J., THIELEN, J., RAMOS, M.H. (2013). Preface: Hydrological ensemble prediction systems. *Hydrological Processes*, 27, 1-4. DOI: 10.1002/hyp.9679
- COLLISCHONN, W., & TUCCI, C. E. (2005a). Previsão Sazonal de Vazão na Bacia do Rio Uruguai 1: Ajuste e Verificação do Modelo Hidrológico Distribuído. RBRH – Revista Brasileira de Recursos Hídricos, 43-59.
- COLLISCHONN, W., TUCCI, C. E., & CLARKE, R. T. (2005b). Previsão Sazonal de Vazão na Bacia do Rio Uruguai 2: Previsão Climática-Hidrológica. RBRH – Revista Brasileira de Recursos Hídricos, 61-72.
- COLLISCHONN, W., TUCCI, C. E., CLARKE, R. T., CORBO, M. D., SILVA, B. C., COLLISCHONN, B., . . . PAZ, A. R. (2007). Modelo Hidrológico Distribuído para Previsão de Vazões Incrementais na Bacia do Rio Paranaíba entre Itumbiara e São Simão. RBRH — Revista Brasileira de Recursos Hídricos, 43-55.
- COLLISCHONN, W.; TUCCI, C. E. M. Simulação hidrológica de grandes bacias. *Revista Brasileira de Recursos Hídricos*, v. 6, n. 1, p. 95-118, 2001. <http://dx.doi.org/10.21168/rbrh.v6n1.p95-118>.
- Collischonn, W.; Bravo, J. M.; da Silva, B. C.; Rodriguez, D. A. (2014). Capítulo 3: “Modelagem Hidrológica”. Em: LIMA, J. W. M., COLLISCHON, W., MARENKO, J. A. 2014. Efeitos das mudanças climáticas na geração de energia elétrica. Editora BH. São Paulo, Brasil.
- COLOSSI, B. R. ; FLEISCHMANN, A. S. ; SIQUEIRA, V. A. ; BITAR, A. A. ; PAIVA, R. C. D. ; FAN, F. M. ; RUHOFF, A. L. ; PONTES, P. R. M. (2017a). Using SMOS for validation and parameter estimation of a large scale hydrological model in Paraná river basin. In: European Geosciences Union General Assembly 2017, 2017, Viena Austria. European Geosciences Union General Assembly 2017. Viena: EGU, 2017. p. EGU2017-9360.
- COLOSSI, B. R. ; FLEISCHMANN, A. S. ; SIQUEIRA, V. A. ; PAIVA, R. C. D. ; FAN, F. M. ; RUHOFF, A. L. ; PONTES, P. R. M. ; COLLISCHONN, W.(2017b) . Validação do modelo hidrológico MGB-IPH com umidade do solo da missão SMOS na bacia do Alto Paraná. In: XVIII Simpósio Brasileiro de Sensoriamento Remoto, 2017, Santos, SP. Anais do XVIII SBSR. Santos: INPE, 2017. p. 1-8.
- CUI, B., TOTH, Z., ZHU, Y., & HOU, D. (2011). Bias correction for global ensemble forecast. *Weather and Forecasting*, 396-410.
- CUO, L., PAGANO, T. C., & WANG, Q. J. (2011). A review of quantitative precipitation forecasts and their use in short-to-medium streamflow forecasting. *Journal of Hydrometeorology*. 12, 713–728, <https://doi.org/10.1175/2011JHM1347.1>.
- CZAJA, A. P.; VAART, V.D.; MARSHALL, J. (2002). “A diagnostic Study of the Role of Remote Forcing in Tropical Atlantic Variability”. *Journal of Climate*, v. 15, p. 3280-3290.
- DALE, M.; WICKS, J.; MYLNE, K.; PAPPENBERGER, F.; LAEGER, S.; TAYLOR, S. Probabilistic flood forecasting and decision making: an innovative risk-based approach. *Nat. Hazard.* ISSN:1573-0840, Springer Netherlands, 2012.
- DANCE, S.L. & ZOU, Q.P. (2010). “Ensembles, uncertainty and flood prediction”. *Hydrol. Earth Syst. Sci. Discuss.*, 7, p.3591-3611, 2010.
- Das, T., Bárdossy, A., Zehe, E., & He, Y. (2008). Comparison of conceptual model performance using different representations of spatial variability. *Journal of Hydrology*, 106– 118.
- DIETRICH, J.; SCHUMANN, A.H.; REDETZKY, M.; WALTHER, J.; DENHARD, M.; WANG, Y.; PFUTZNER, B.; BUTTNER, U. Assessing uncertainties in flood forecasts for decision making: prototype of an operational flood management system integrating ensemble predictions. *Nat. Hazards Earth Syst. Sci.*, v. 9, p.1529–1540, 2009.
- ECMWF, E. C.-R. (2017a). SEAS5 User Guide.
- ECMWF, E. C.-R. (2017b). IFS DOCUMENTATION - Cy43r3. PART V: ENSEMBLE PREDICTION SYSTEM.
- FAN, F. M., COLLISCHONN, W., MELLER, A., & BOTELHO, L. C. (2014). Ensemble streamflow forecasting experiments in a tropical basin: The São Francisco river case study. *Journal of Hydrology*, Volume 519, Part D, 27 November 2014, Pages 2906-2919. <https://doi.org/10.1016/j.jhydrol.2014.04.038>
- FAN, F. M., COLLISCHONN, W., QUIROZ, K. J., SORRIBAS, M. V., BUARQUE, D. C., & SIQUEIRA, V. A. (2015d). Flood forecasting on the Tocantins River using ensemble rainfall forecasts and real-time satellite rainfall estimates. *Journal of Flood Risk Management*, 1-11.

- FAN, F. M., PONTES, P. R., COLLISCHONN, W., & BUARQUE, D. C. (2015a). Sobre o uso da persistência de previsões determinísticas de vazão para a tomada de decisão. *Revista Brasileira de Meteorologia*, 218-228.
- FAN, F. M., RAMOS, M.-H., & COLLISCHONN, W. (2015b). Sobre o uso de previsões hidrológicas probabilísticas para a tomada de decisão. *Revista Brasileira de Recursos Hídricos*, 914-926.
- FAN, F. M., SCHWANENBERG, D., COLLISCHONN, W., & WEERTS, A. (2015c) Verification of inflow into hydropower reservoirs using ensemble forecasts of the TIGGE database for large scale basins in Brazil. *Journal of Hydrology* Volume 4, Part B, September 2015, Pages 196-227. <https://doi.org/10.1016/j.ejrh.2015.05.012>
- FAN, F. M.; SCHWANENBERG, D.; ALVARADO, R. ; REIS, A. A. ; COLLISCHONN, W. ; NAUMANN, S. (2016). Performance of Deterministic and Probabilistic Hydrological Forecasts for the Short-Term Optimization of a Tropical Hydropower Reservoir. *Water Resources Management*, p. 1-17.
- FOSTER, K., UVÖ, C. B., & OLSSON, J. (2017). The development and evaluation of a hydrological seasonal forecast system prototype for predicting spring flood volumes in Swedish rivers. *Hydrology and Earth System Sciences*, 1-29.
- GEORGAKAKOS, K.P., KRZYSZTOFOWICZ, R. (2001). Probabilistic and ensemble forecasting. Volume 249, Issues 1–4, 1 August 2001, Page 1. [https://doi.org/10.1016/S0022-1694\(01\)00455-3](https://doi.org/10.1016/S0022-1694(01)00455-3)
- GODDARD, L., AITCHELLOUCHE, Y., BAETHGENA, W., DETTINGER, M., GRAHAM, R., HAYMANE, P., & CONRAD, E. (2010). Providing Seasonal-to-Interannual Climate Information for Risk Management and Decision making. *Procedia Environmental Sciences*, 81–101.
- GODDARD, L., MASON, S. J., ZEBIAK, S. E., ROPELEWSKI, C.F., CANE, M. A. (2001). Current approaches to seasonal-to-interannual climate predictions. *International Journal of Climatology*, v21, p.1111-1152.
- GOLDING, B. W. (2014). “Regional Prediction Models”. Em: North, G. R.; Pyle, J. A.; Zhang, F. (2014). “Encyclopedia of Atmospheric Sciences”. Academic Press, 2nd Edition, 2008.
- GOLDING, B. W. Long lead time flood warnings: reality or fantasy? *Met. Apps*, v. 16, p. 3– 12, 2009doi: = 10.1002/met.123.
- GREUELL, W., FRANSSEN, W. H., BIEMANS, H., & HUTJES, R. W. (2018). Seasonal streamflow forecasts for Europe – Part I: Hindcast verification with pseudo- and real observations. *Hydrology and Earth System Sciences* 22 (2018)6. - ISSN 1027-5606 - p. 3453 - 3472. <https://doi.org/10.5194/hess-22-3453-2018>
- GUDMUNDSSON, L., BREMNES, J. B., HAUGEN, J. E., & ENGEN-SKAUGEN, T. (2012). Technical Note: Downscaling RCM precipitation to the station scale using statistical transformations – a comparison of methods. *Hydrology and Earth System Sciences*, 3383–3390.
- HAMILL, T., HAGEDORN, R., WHITAKER, J., (2008). Probabilistic forecast calibration using ECMWF and GFS ensemble reforecasts. Part II: Precipitation. *Mon. Weather Rev.* 136 (7), 2620–2632.
- HAMLET, A. F.; HUPPERT, D.; LETTENMAIER. (2002). “Economic values of long-lead streamflow forecasts for Columbia River Hydropower”. *Journal of the Water Resources Planning and Management*”, v. 128(2), p. 91-101.
- HANSEN, J. W., CHALLINOR, A., INES, A., WHEELER, T., & MORON, V. (2006). Translating climate forecasts into agricultural terms: advances and challenges. *CLIMATE RESEARCH*, 27–41.
- HARTMANN, H. (2005). Use of Climate Information in Water Resources Management. *Encyclopedia of Hydrological Sciences*, 1-15.
- HAY, L., & CLARK, M. (2003). Use of statistically and dynamically downscaled atmospheric model output for hydrologic simulations in three mountainous basins in the western United States. *Journal of Hydrology*, 56–75.
- HOSKINS, B. (2013). The potential for skill across the range of the seamless weather-climate prediction problem: a stimulus for our science. *Quarterly Journal of the Royal Meteorological Society*, 573–584.
- HSIEH, W. W.; YUVAL, L. J.; SHABBAR, A. SMITH, S. (2003). “Seasonal prediction with error estimation of Columbia River Streamflow in British Columbia”. *Journal of water Resources Planning and Management*, v. 129(2), p. 146-149.
- HSU, M. H.; FU, J. C.; LIU, W. C. (2003). “Flood routing with real-time stage correction method for flash flood forecasting in the Tanshui River, Taiwan”. *Journal of Hydrology*, v. 283, p. 287-280.

- JANCLOES, M., THOMSON, M., COSTA, M. M., & HEWITT, C. (2014). Climate Services to Improve Public Health. International Journal of Environmental Research and Public Health, 4555-4559.
- JOLLIFFE, I. T; STEPHENSON, D. B. (2003). "Forecast Verification: A practitioner's Guide in Atmospheric Science". John Wiley & Sons Ltd. 2003, p. 247.
- KALLACHE, M., VRAC, M., NAVEAU, P., & MICHELANGELI, P.-A. (2011). Nonstationary probabilistic downscaling of extreme precipitation. JOURNAL OF GEOPHYSICAL RESEARCH, 1-15.
- KALNAY, E. (2003). "Atmospheric Modeling, Data Assimilation and Predictability". Cambridge University Press. UK. 276p.
- KAYANO, M. T.; ANDREOLI, R. V. (2004) "Decadal Variability of Northern Brazil rainfall and its relation to tropical sea surface temperature and global sea level pressure anomalies". Journal Geophys. Res., v. 109, p. 21-32.
- KELLY-HOPE, L., & THOMSON, M. C. (2008). Climate and Infectious Diseases. Em M. C. Thomson, R. Garcia Herrera, & M. Beniston, Seasonal Forecasts, Climatic Change and Human Health (p. 232). Springer.
- KIRCHHOFF, C. J., LEMOS, M. C., & DESSAI, S. (2013). Actionable Knowledge for Environmental Decision Making: Broadening the Usability of Climate Science. The Annual Review of Environment and Resource, 393–414.
- KOSTER, R. D., ET AL. (2010). Contribution of land surface initialization to subseasonal forecast skill: First results from a multi-model experiment. GEOPHYSICAL RESEARCH LETTERS, 1-6.
- KOUSSIS, A. D; LAGOUVARDOS, K.; MAZI, K.; KOTRONI, V.; SITZMANN, D.; LANG, J.; ZAISS, H; BUZZI, A.; MALGUZZI, P. (2003). "Flood Forecasts for Urban Basin with integrated Hydro-Meteorological Model". Journal of Hydrologic Engineering, v. 8(1), p. 1-11.
- KRZYSZTOFOWICZ, R. (1998). Probabilistic hydrometeorological forecasts: Toward a new era in operational forecasting. Bulletin of the American Society, 243-252.
- KRZYSZTOFOWICZ, R. (2001). The case for probabilistic forecasting in hydrology. Volume 249, Issues 1–4, 1 August 2001, Pages 2-9. [https://doi.org/10.1016/S0022-1694\(01\)00420-6](https://doi.org/10.1016/S0022-1694(01)00420-6)
- KUHN, K., CAMPBELL-LENDRUM, D., HAINES, A., & COX, J. (2005). Using climate to predict infectious disease epidemics. Geneva: World Health Organization Press.
- LEMOS, M. C. (2008). What influences innovation adoption by water managers? Climate information use in brazil and the united states. JOURNAL OF THE AMERICAN WATER RESOURCES ASSOCIATION, 1388-1396.
- LEMOS, M. C., & MOREHOUSE, B. J. (2005). The co-production of science and policy in integrated climate assessments. Global Environmental Change, 57–68.
- LETTERMAIER, D. P.; WOOD, E. F. (1993). Hydrologic Forecasting. In: Maidment (Org.), Handbook of Hydrology. Ed McGraw-Hill
- LIN, Y., RAY, P.; JOHNSON, K. (1993). "Initialization of a modelled convective storm using Doppler radar derived fields". Monthly Weather Review, v.121, p. 2757-2775, 1993.
- LORENZ, E. N. (1963). "Deterministic non-periodic flow". J. Atmos. Sci., v. 20, p. 130-141.
- LORENZ, E. N. (1965). "A study of the predictability of a 28-variable atmospheric model". Tellus, v. 17, p. 321-333.
- LORENZ, E. N. (1969). "The predictability of a flow which contains many scales of motion. Tellus, v. 21A, p. 289 307.
- LUCATERO, D., MADSEN, H., REFSGAARD, J. C., KIDMOSE, J., AND JENSEN, K. H (2018).: Seasonal streamflow forecasts in the Ahlergaard catchment, Denmark: the effect of preprocessing and post-processing on skill and statistical consistency, Hydrol. Earth Syst. Sci., 22, 3601–3617, <https://doi.org/10.5194/hess-22-3601-2018>, 2018b.
- MARAUN, D. (2013). Bias Correction, Quantile Mapping, and Downscaling: Revisiting the Inflation Issue. American Meteorological Society, 2137-2143.
- MARAUN, D., WETTERHALL, F., IRESON, A. M., CHANDLER, R. E., KENDON, E. J., WIDMANN, M., . . . THIELE-EICH, I. (2010). PRECIPITATION DOWNSCALING UNDER CLIMATE CHANGE: RECENT

DEVELOPMENTS TO BRIDGE THE GAP BETWEEN DYNAMICAL MODELS AND THE END USER. *Reviews of Geophysics*, 1-34.

- MASE, A., & PROKOPY, L. (2014). Unrealized Potential: A Review of Perceptions and Use of Weather and Climate Information in Agricultural Decision Making. American Meteorological Society, 47-61.
- MCCOLLOR, D.; STULL, R. Hydrometeorological Short-Range Ensemble Forecasts in Complex Terrain. Part II: = Economic Evaluation. *Weather and Forecasting*, v. 23, p. 557-574, 2008, doi: 10.1175/2007WAF2007064.1
- MCGUFFIE, K.; HENDERSON-SELLERS, A. (1997). "A climate Modelling Primer". England: John Wiley & Sons. 253p.
- MEIßNER, D., KLEIN, B., & IONITA, M. (2017). Development of a monthly to seasonal forecast framework tailored to inland waterway transport in central Europe. *Hydrology and Earth System Science*, 6401-6423.
- MELLER, A.; COLLISCHONN, W.; FAN, F.M.; BUARQUE, D.C.; PAIVA, R.C.D.; DIAS, P.; MOREIRA, D. Previsão de Cheias por Conjunto em Curto Prazo. *Revista Brasileira de Recursos Hídricos*, v. 19, p. 33-49, 2014.
- MONHART, S., ZAPPA, M., SPIRIG, C., SCHAR, C., BOGNER, K. (2019). Subseasonal hydrometeorological ensemble predictions in small- and medium-sized mountainous catchments: benefits of the NWP approach. *Hydrol. Earth Syst. Sci.*, 23, 493–513, <https://doi.org/10.5194/hess-23-493-2019>
- MOORE, R. J.; BELL, V. A.; JONES, D. A. (2005). "Forecasting for flood warning". *Computes Rendus Geoscience*, v. 337, p. 203-217.
- MORSS, R. E., LAZO, J. K., BROWN, B. G., BROOKS, H. E., GANDERTON, P. T., & MILLS, B. N. (2008). Societal and economic research and applications for weather forecasts. *American meteorological society*, 335-346.
- MURPHY, A. H. (1993). "What is a good forecast? An essay on the nature of goodness in weather forecasting". *Wea. Forecasting*, v. 8, p. 281-293, 1993
- NAMIAS, J. (1972). "Influence of Northern Hemisphere Ciculation on Drought in Northes Brazil". *Tellus*, v.24, p. 336-342.
- NASEM. The National Academies of Sciences, E. a. (2010). Assessment of Intraseasonal to Interannual Climate Prediction and Predictability. Washington, D.C.: The National Academy Press.
- NASEM. THE NATIONAL ACADEMIES OF SCIENCES, E. A. (2016). Next Generation Earth System Prediction: Strategies for Subseasonal to Seasonal forecasts. Washington, D.C.: The National Academy Press.
- NEAL, E. G.; WALTER, M. T.; COFFEN, C. (2002). "Linking the Pacific oscillation to seasonal stream discharge patterns in Southeast Alaska". *Journal of Hydrology*, v. 263, p. 188-197.
- NILSSON, P.; UVÖ, C. B.; BERNDTSSON, R. (2006). "Monthly runoff simulation: comparison of a conceptual model, neural networks anda combination of them". *Journal of Hydrology*, v. 321, p. 344- 363.
- NOBERT, S., DEMERITT, D. & CLOKE, H. (2010). "Informing operational flood management with ensemble predictions: lessons from Sweden. *Journal of Flood Risk Management*". 3, p.72 79, 2010.
- NOBRE, P., SHUKLA, J. (1996). "Variations of sea surface temperature, wind stress and rainfall over the tropical Atlantic and South America". *Journal of climate*, v. 10(4), p. 2464-2479.
- O'CONNOR, R. E., YARNAL, B., DOW, K., & JOCOY, C. L. (2005). Feeling at Risk Matters:Water Managers and the Decision to Use Forecasts. *Risk Analysis*, 1265-1275.
- O'DONNELL, M., & BONNIE COLBY. (2009). Dry-Year Water Supply Reliability Contracts: A Tool for Water Managers. Arizona: The University of Arizona.
- OGALLO, L. A.; BOULAHYA, M. S.; KEANE, T. (2000). "Applications of seasonal to interannual climate prediction in agricultural planning and operations". *Agricultural and Forest Mteorology*, v. 103, p. 159-166.
- OLSSON, J.; LINDSTROM, G. Evaluation and calibration of operational hydrological ensemble forecasts in Sweden. *J. Hydrol.*, v. 350, p.14-24, 2008.
- OLSSON, J.; UVÖ, C. B.; JINNO, K.; KAWAMURA, A.; NISHIYAMA, K; KOREEDA, N.; NAKASHIMA, T; MORITA, O. (2004). "Neural Networks for rainfall forecasting by atmospheric downscaling". *Journal of Hydrologic Engineering*, v. 9(1), p. 1-12.

- ONS – Operador Nacional do Sistema, 2011. Procedimentos de Rede Submódulo 9.5: Previsão de Vazões e Gerac, ão de Cenários de Afluências, vol. 2., pp. 9.
- ONS – Operador Nacional do Sistema, 2012a. Diretrizes para as Regras de Operac, ão de Controle de Cheias – Bacia do Rio São Francisco (Ciclo 2012–2013). ONS RE 3/166/2012., pp. 158.
- ONS – Operador Nacional do Sistema, 2012b. Inventário das Restric, ões Operativas Hidráulicas dos Aproveitamentos Hidrelétricos (Revisão 1 de 2012). ONS RE 3/0105/2012., pp. 154.
- ONS – Operador Nacional do Sistema, 2014. Diretrizes para as Regras de Operac, ão de Controle de Cheias – Bacia do Rio Iguaçu,(Ciclo 2013–2014). ONS RE 3/0064/2014., pp. 48.
- PAGANO, T. C., HARTMANN, H. C., & SOROOSHIAN, S. (2002). Factors affecting seasonal forecast use in Arizona water management: a case study of the 1997-98 El Niño. CLIMATE RESEARCH, 259–269.
- PAGANO, T.C.; WOOD, A. W.; RAMOS, M.-H.; CLOKE, H. L.; PAPPENBERGER, F.; CLARK, M. P.; CRANSTON, M.; KAVETSKI, D.; MATHEVET, T.; SOROOSHIAN, S.; VERKADE, J. S. (2014). “Challenges of Operational River Forecasting”. Journal of Hydrometeorology, v. 15, n. 4, p. 1692-1707, doi: 10.1175/JHM-D-13 0118.1.
- PALMER, R. B.-Y. (2007). The Ensemble Prediction System - Recent and Ongoing Developments. Fonte: Series: ECMWF Technical Memoranda: <http://www.ecmwf.int/publications/>
- PANOFSKY, H. A., & BRIER, G. W. (1968). Some Applications of Statistics to Meteorology. Pennsylvania, US.
- PAPPENBERGER, F. BROWN, J. D. (2013). HP today: on the pursuit of (im)perfection in flood forecasting. Hydrological Processes. Hydrol. Process. 27, 162–163. DOI: 10.1002/hyp.9465
- PAPPENBERGER, F.; BEVEN, K.J.; HUNTER, N.M.; BATES, P.D.; GOUWELEEUW, B.T.; THIELEN, J.; DE ROO; A.P.J. (2005). “Cascading model uncertainty from medium range weather forecasts (10 days) through a rainfall runoff model to flood inundation predictions within the European Flood Forecasting System (EFFS)”. Hydrol.Earth Syst. Sci., v.35, p.381-393, 2005.
- PAPPENBERGER, F., STEPHENS, E., THIELEN, J., SALAMON, P., DEMERITT, D., VAN ANDEL, S. J., WETTERHAL, F., ALFIERI, L. (2013). Visualizing probabilistic flood forecast information: expert preferences and perceptions of best practice in uncertainty communication. Hydrol. Process.27, 132–146 (2013). DOI: 10.1002/hyp.9253
- PAPPENBERGER, F.; BOGNER, K.; WETTERHALL, F.; HE, Y.; CLOKE, H. L.; THIELEN, J. (2011a). “Forecast convergence score: a forecaster’s approach to analyzing hydro-meteorological forecast systems”. Adv. Geosci., v. 29, p. 27-32, doi: 10.5194/adgeo-29-27-2011.predictions. Hydrol. Earth Syst. Sci., v. 16, p. 815–831, 2012.
- PAPPENBERGER, F., STEPHENS, E., THIELEN., DEL MEDICO, M. (2011b). The impact of weather forecast improvements on large scalehydrology: analysing a decade of forecasts of the EuropeanFlood Alert System. Hydrol. Process.25, 1091 – 1113 (2011). DOI: 10.1002/hyp.7772
- PATT, A. G., OGALLO, L., & HELLMUTH, M. (2007). Learning from 10 Years of Climate Outlook Forums in Africa. SCIENCE, 49-50.
- PEREZ, E. C., & MASON, S. J. (2014). Climate information for humanitarian agencies: some basic principles. Earth Perspectives, 1-6.
- PEREZ, E. C., STEPHENS, E., BISCHINOTIS, K., & AALST, M. V. (2017). Should seasonal rainfall forecasts be used for flood preparedness? Hydrology and Earth System Sciences, 4517-4524.
- PIANI, C., HAERTER, J. O., & COPPOLA, E. (2010). Statistical bias correction for daily precipitation in regional climate models over Europe. Theoretical and Applied Climatology, 187–192.
- PIERCE, C.; SEED, A.; BALLARD, S.; SIMONIN, D.; LI, Z. (2012). “Nowcasting, Doppler Radar Observations Weather Radar, Wind Profiler, Ionospheric Radar, and Other Advanced Applications, Dr. Joan Bech (Ed.), ISBN: 978 953-51-0496-4.
- PONTES, P. R. M. ; FAN, F. M. ; COLLISCHONN, W. ; BUARQUE, D. C. ; SORRIBAS, M. VN. (2012). Calibração e Verificação do Modelo Hidrológico MGB-IPH para a Bacia do Paraná. In: XI Simpósi o de Recursos Hídricos do Nordeste, 2012, João Pessoa ? PB. Calibração e Verificação do Modelo Hidrológico MGB-IPH para a Bacia do Paraná, 2012.

- PONTES, P. R. M. ; FAN, F. M. ; COLLISCHONN, W. ; PAIVA, R. C. D. (2013) . Análise da Sensibilidade da Vazão do Rio Paraná a Pontencial Alteração da Precipitação. In: XX Simpósio Brasileiro de Recursos Hídricos, 2013, Bento Gonçalves - RS. Anais XX Simpósio Brasileiro de Recursos Hídricos, 2013.
- RAMOS, M.H.; MATHEVET, T.; THIELEN, J.; PAPPENBERGER, F. (2010). "Communicating uncertainty in hydro meteorological forecasts: mission impossible?". *Meteorological Applications*, v. 17, p. 223-235, 2010.
- RAMOS, M.H.; VAN ANDEL, S.J.; PAPPENBERGER, F. Do probabilistic forecasts lead to better decisions? *Hydrol. Earth Syst. Sci.*, v. 9, n. 17, p. 2219-2232, 2013, doi:10.5194/hess-17-2219-2013.
- REITER, P., GUTJAHR, O., SCHEFCZYK, L., HEINEMANN, G., & CASPER, M. (2015). Bias correction of ENSEMBLES precipitation data with focus on the effect of the length of the calibration period. *Meteorologische Zeitschrift*, 85–96.
- REITER, P., GUTJAHR, O., SCHEFCZYK, L., HEINEMANN, G., & CASPER, M. (2017). Does applying quantile mapping to subsamples improve the bias correction of daily precipitation? *INTERNATIONAL JOURNAL OF CLIMATOLOGY*, 1-11.
- RICHARDSON, D. S. (2000). Skill and relative economic value of the ECMWF ensemble prediction system. *Quarterly Journal of the Royal Meteorological Society*, 649-667.
- ROBERTSON, A. W., BAETHGEN, W., BLOCK, P., LALL, U., SANKARASUBRAMANIAN, A., FILHO, F. D., & VERBIST, K. M. (2014). Climate risk management for water in semi-arid regions. *Earth Perspectives*, 1-12.
- ROULIN, E. Skill and relative economic value of medium-range hydrological ensemble predictions. *Hydrol. Earth Syst. Sci.*, v. 11, p.725–737, 2007, doi:10.5194/hess-11 725-2007.
- SAMPAIO, G.; DIAS, P. L. S. (2014). Evolução dos modelos climáticos e de previsão de tempo e clima. *Revista USP*, São Paulo, n. 103, p. 41-54.
- SCHAAKE, J.; FRANZ, K.; BRADLEY, A.; BUIZZA, R. (2006). "The Hydrologic Ensemble Prediction Experiment (HEPEX)". *Hydrol. Earth Syst. Sci. Discuss.*, v. 3, p.3321–3332, 2006.
- SCHELLEKENS, J.; WEERTS, A.H.; MOORE, R.J.; PIERCE, C.E; HILDON, S. (2011). "The use of MOGREPS ensemble rainfall forecasts in operational flood forecasting systems across England and Wales". *Adv. Geosci.*, 29, p.77–84, 2011.
- SCHERRER, S. C.; APPENZELLER, C.; ECKERT, P.; CATTANI, D. Analysis of the spread-skill relations using the ECMWF ensemble prediction system over Europe. *Wea. Forecasting*, v. 19, p. 552 – 565, 2004.
- SCHMIDLI, J., FREI, C., & VIDALE, P. L. (2006). Downscaling from gcm precipitation: a benchmark for dynamical and statistical downscaling methods. *INTERNATIONAL JOURNAL OF CLIMATOLOGY*, 679–689.
- Schmidli, J., Goodess, C. M., Frei, C., Haylock, M. R., Hundecha, Y., Ribalaygua, J., & Schmitt, T. (2007). Statistical and dynamical downscaling of precipitation: An evaluation and comparison of scenarios for the European Alps. *JOURNAL OF GEOPHYSICAL RESEARCH*, 1-20.
- SHAH, R., SAHAI, A. K., & MISHRA, V. (2017). Short to sub seasonal hydrologic forecast to manage water and agricultural resources in India. *Hydrology and Earth System Science*, 707–720.
- SHAPIRO, M. A., AND COAUTHORS, 2010: An Earth-system prediction initiative for the twenty-first century. *Bull. Amer. Meteor. Soc.*, 91, 1377–1388.
- SCHWANENBERG, DIRK., FAN, FERNANDO MAINARDI., NAUMANN, STEFFI., KUWAJIMA, JULIO ISSAO., MONTERO, RODOLFO ALVARADO., ASSIS DOS REIS, ALBERTO. (2015). Short-Term Reservoir Optimization for Flood Mitigation under Meteorological and Hydrological Forecast Uncertainty. *Water Resources Management*, 0920-4741, 1-17, <http://dx.doi.org/10.1007/s11269-014-0899-1>.
- SILVESTRI, G. E.; VERA, C. S. (2003). "Antartic Oscillation signal on precipitation anomalies over southeastern South America". *Geophysical Research Letters*, v. 30(21), 4p.
- SIQUEIRA, B., MARTINS, G., NERY, J.T. (2018). Variabilidade Sazonal da precipitação na bacia do Paraná no território brasileiro. *Revista Brasileira de Climatologia*. 16p
- SIQUEIRA, V. A., COLLISCHONN, W., FAN, F.M., CHOU, S. C. (2016b). Ensemble flood forecasting based on operational forecasts of regional Eta EPS in the Taquari-Antas basin. *RBRH*. vol.21, n.3, pp.587-602. ISSN 2318-0331. <http://dx.doi.org/10.1590/2318-0331.011616004>.

- SIQUEIRA, V. A., FLEISCHMANN, A., JARDIM, P. F., FAN, F. M., & COLLISCHONN, W. (2016a). IPH-Hydro Tools: a GIS coupled tool for watershed topology acquisition in an opensource environment. RBRH - Revista Brasileira de Recursos Hídricos, 274- 287.
- SIQUEIRA, V. A., PAIVA, R. C. D., FLEISCHMANN, A. S., FAN, F. M., RUHOFF, A. L., PONTES, P., R., M., PARIS, A., CALMANT, S., COLLISCHONN, W. (2018). Toward continental hydrologic–hydrodynamic modeling in South America. *Hydrol. Earth Syst. Sci.*, 22, 4815-4842, 2018. <https://doi.org/10.5194/hess-22-4815-2018>
- SOBOLOWSKI, S., GONG, G., & TING, M. (2010). Modeled Climate State and Dynamic Responses to Anomalous North American Snow Cover. American Meteorological Society, 785-799.
- SRINIVASAN, G., RAFISURA, K. M., & SUBBIAH, A. R. (2011). Climate information requirements for community level risk management and adaptation. CLIMATE RESEARCH, 5–12.
- SUAREZ, P., & TALL, A. (2010). Towards forecast-based humanitarian decisions: Climate science to get from early warning to early action. Humanitarian Futures Programme, 1-10.
- TEUTSCHBEIN, C., & SEIBERT, J. (2012). Bias correction of regional climate model simulations for hydrological climate-change impact studies: Review and evaluation of different methods. *Journal of Hydrology*, 12–29.
- THEMEBL, M. J., & LEUPRECHT, A. G. (2011). Empirical-statistical downscaling and error correction of daily precipitation from regional climate models. *INTERNATIONAL JOURNAL OF CLIMATOLOGY*, 1530–1544.
- THOMSON, M. C., DOBLAS-REYES, F. J., MASON, S. J., HAGEDORN, R., CONNOR, S. J., PHINDELA, T., & MORSE, A. P. (2006). Malaria early warnings based on seasonal climate forecasts from multi-model ensembles. *Nature*, 576–579.
- THOMSON, M. C., MASON, S., PLATZER, B., MIHRETIE, A., OMUMBO, J., & MANTILLA, G. (2014). Climate and health in Africa. *Earth Perspectives*, 1-12.
- TIAN, D., WOOD, E. F., & YUAN, X. (2016). CFSv2-based sub seasonal precipitation and temperature forecast skill over the contiguous United States. *Hydrology and Earth System Sciences*, 1477-1490.
- Tucci, C. E., Clarke, R. T., & Collischonn, W. (2003). Long-term flow forecasts based on climate and hydrologic. *WATER RESOURCES RESEARCH*, 1-11.
- TURNER, S. W., BENNETT, J. C., ROBERTSON, D. E., & GALELLI, S. (2017). Complex relationship between seasonal streamflow forecast skill and value in reservoir operations. *Hydrology and Earth System Sciences*, 4841 4859.
- VERKADE, J. S.; WERNER, M. G. F. Estimating the benefits of single value and probability forecasting for flood warning. *Hydrol. Earth Syst. Sci.*, v. 15, p. 3751-3765, 2011. doi:10.5194/hess-15-3751-2011.
- VITART, F., & ROBERTSON, A. W. (2018). The sub seasonal to seasonal prediction project (S2S) and the prediction of extreme events. *Climate and Atmospheric Science*, 1-7.
- VITART, F., BUIZZA, R., BALMASEDA, M. A., BALSAMO, G., BIDLOT, J.-R., BONET, A., . . . PALMER, T. N. (2008). The new Var-EPS-monthly forecasting system: A first step towards seamless prediction. *Quarterly Journal of the Royal Meteorological Society*, 1789-1799.
- VITART, F., BUIZZA, R., BALMASEDA, M. A., BALSAMO, G., BIDLOT, JR., BONET, A., FUENTES, M., HOFSTADLER, A., MOLTENI, F., PALMER, T. (2008). The new VarEPS–monthly forecasting system: A first step towards seamless prediction. *QUARTERLY JOURNAL OF THE ROYAL METEOROLOGICAL SOCIETY*. Q. J. R. Meteorol. Soc. 134: 1789–1799. DOI: 10.1002/qj.322
- VITART, F., C. ARDILOUZE, A. BONET, A. BROOKSHAW, M. CHEN, C. CODOREAN, M. DÉQUÉ, L. FERRANTI, E. FUCILE, M. FUENTES, H. HENDON, J. HODGSON, H. KANG, A. KUMAR, H. LIN, G. LIU, X. LIU, P. MALGUZZI, I. MALLAS, M. MANOUSSAKIS, D. MASTRANGELO, C. MACLACHLAN, P. MCLEAN, A. MINAMI, R. MLADEK, T. NAKAZAWA, S. NAJM, Y. NIE, M. RIXEN, A.W. ROBERTSON, P. RUTI, C. SUN, Y. TAKAYA, M. TOLSTYKH, F. VENUTI, D. WALISER, S. WOOLNOUGH, T. WU, D. WON, H. XIAO, R. ZARIPOV, AND L. ZHANG. (2017). The Subseasonal to Seasonal (S2S) Prediction Project Database. *Bull. Amer. Meteor. Soc.*, 98, 163–173. <https://doi.org/10.1175/BAMS-D-16-0017.1>.
- VITART, F., ROBERTSON, A. W., & ANDERSON, D. L. (2012). Subseasonal to Seasonal Prediction Project: bridging the gap between weather and climate. *WMO Bulletin*, 23-28.

- VITART, F., ROBERTSON, A. W., & GROUP, S. S. (2015). CHAPTER 20. SUB SEASONAL TO SEASONAL PREDICTION: LINKING WEATHER AND CLIMATE. Em W. M. (WMO), *SEAMLESS PREDICTION OF THE EARTH SYSTEM: FROM MINUTES TO MONTHS* (p. 483). Geneva, Switzerland: WMO.
- WALISER, D. (2005). Predictability and Forecasting. Em; W. Lau, & D. Waliser, *Intraseasonal Variability in the Atmosphere-Ocean climate system* (p. 457). Chichester, UK: Praxis Publishing.
- WATTERSON, I. G. (2009) "Components of precipitation and temperature anomalies and change associated with models of the Southern Hemisphere". *Hydrological Processeces*, v. 29, p. 809-826.
- WETTERHALL, F., & GIUSEPPE, F. D. (2018). The benefit of seamless forecasts for hydrological predictions over Europe. *Hydrology and Earth System Sciences*, 3409–3420.
- WHITE, C. J., CARLSEN, H., ROBERTSON, A. W., KLEIN, R. J. T., LAZO, J. K., KUMAR, A., VITART, F., = COUGHLAN DE PEREZ, E., RAY, A. J., MURRAY, V., BHARWANI, S., MACLEOD, D., JAMES, R., FLEMING, L., MORSE, A. P., EGGEN, B., GRAHAM, R., KJELLSTRÖM, E., BECKER, E., PEGION, K. V., HOLBROOK, N. J., MCEVOY, D., DEPLEDGE, M., PERKINS-KIRKPATRICK, S., BROWN, T. J., STREET, R., JONES, L., REMENYI, T. A., HODGSON-JOHNSTON, I., BUONTEMPO, C., LAMB, R., MEINKE, H., ARHEIMER, B., AND ZEBIAK, S. E. (2017). Potential applications of subseasonal-to-seasonal (S2S) predictions, *Meteorol. Appl.*, 24, 315–325. <https://doi.org/10.1002/met.1654>.
- WILKS, D. (2006). *STATISTICAL METHODS IN THE ATMOSPHERIC SCIENCES*. London, UK: Elsevier.
- WILKS, D. S., & HAMILT, T. M. (1995). Potential Economic Value of Ensemble-Based Surface Weather Forecast. American Meteorological Society, 3565-3575.
- WOOD, A. W., MAURER, E. P., KUMAR, A., & LETTENMAIER, D. P. (2002). Long-range experimental hydrologic forecasting for the eastern United States. *JOURNAL OF GEOPHYSICAL RESEARCH*, 1-15.
- WOOLNOUGH, S. J., VITART, F., & BALMASEDA, M. A. (2007). Implications for MJO prediction: The role of the ocean in the Madden-Julian Oscillation: *QUARTERLY JOURNAL OF THE ROYAL METEOROLOGICAL SOCIETY*, 117–128.
- WORLD METEOROLOGICAL ORGANIZATION (WMO). (2018.). WWRP/WCRP Sub-seasonal to Seasonal Prediction Project (S2S) Phase II Proposal (Nov 2018 – Dec 2023).
- XU, C.-Y. (1999). From GCMs to river flow: a review of downscaling methods and hydrologic. *Progress in Physical Geography*, 229–249.
- YUAN, X., WOOD, E. F., & MA, Z. (2015). A review on climate-model-based seasonal hydrologic forecasting: physical understanding and system development. *WIREs Water*, 523-536. <https://doi.org/10.1002/wat2.1088>
- ZAPPA, M; JAUN, S.; GERMAN, U.; WALSER, A. & FUNDEL, F. (2011). "Superposition of three sources of uncertainties in operational flood forecasting chains". *Atmospheric Research*, 100, np.246–262, 2011.
- ZHOU, G., MINAKAWA, N., GITHEKO, A. K., & YAN, G. (2004). Association between climate variability and malaria epidemics in the East African highlands. *Proceedings of the National Academy of Sciences of the United States of America*, 2375-2380.

## 8. Anexo: Descrição do modelo meteorológico *ipsis litteris* portal S2S

- Criado por Frederic Vitart, última alteração em nov 01, 2017  
**Name:** ECMWF Ensemble

The S2S database contains real-time forecasts from ECMWF from **1st January 2015**, and the associated re-forecasts.

# 1. Ensemble version

**Ensemble identifier code:** CY43R3

**Short Description:** Global ensemble system that simulates initial uncertainties using singular vectors and ensemble of data assimilation and model uncertainties due to physical parameterizations using a stochastic scheme. based on 51 members, runs twice a week (Monday and Thursday at 00Z) up to day 46.

**Research or operational:** Operational

**Data time of first forecast run:** 11 July 2017

## 2. Configuration of the EPS

**Is the model coupled to an ocean model ?** Yes from day 0

**If yes, please describe ocean model briefly including frequency of coupling and any ensemble perturbation applied:** Ocean model is NEMO3.4.1 with a 0,25 degree horizontal resolution, 75 vertical levels, initialized from ECMWF Ocean Analysis + 4 perturbed analyses produced by perturbing the wind field during the ocean analysis. Frequency of coupling is hourly.

**Is the model coupled to a sea ice model?** Yes

**If yes, please describe sea-ice model briefly including any ensemble perturbation applied:** Interactive sea-ice model (the Louvain-la-Neuve Sea Ice Model - LIM2). Initial perturbations of sea-ice from the 5 ensemble ocean/sea-ice analysis/re-analysis. No stochastic perturbations.

**Is the model coupled to a wave model?** Yes

**If yes, please describe wave model briefly including any ensemble perturbation applied:** ECMWF wave model. No perturbation. Resolution is 0.25 degrees up to day 15 and 0.5 degrees after day 15.

**Ocean model:** NEMO 0.25 degree resolution

**Horizontal resolution of the atmospheric model:** Tco639 (about 16 km) up to day 15 and Tco319 (about 32 km) after day 15

**Number of model levels:** 91

**Top of model:** 0.01 hPa

**Type of model levels:** sigma

**Forecast length:** 46 days (1104 hours)

**Run Frequency:** twice a week (Monday 00Z and Thursday 00Z)

**Is there an unperturbed control forecast included?** Yes

**Number of perturbed ensemble members:** 50

**Integration time step:** 12 minutes for day 0-15 and 20 minutes for day 15-46

### 3. Initial conditions and perturbations

**Data assimilation method for control analysis:** 4D Var (atmosphere) and 3DVAR (ocean/sea-ice)

**Resolution of model used to generate Control Analysis:** TL1279L137

**Ensemble initial perturbation strategy:** Singular vectors + Ensemble Data Assimilation perturbations added to control analysis

**Horizontal and vertical resolution of perturbations:** T42L91 SVs+ T399L137 EDA perturbations

**Perturbations in +/- pairs:** Yes

#### **Initialization of land surface:**

**What is the land surface model (LSM) and version used in the forecast model, and what are the current/relevant references for the model? Are there any significant changes/deviations in the operational version of the LSM from the documentation of the LSM?** IFS Documentation, Physical Processes, Chapter 8 Surface parameterisation, 2016 <http://www.ecmwf.int/en/elibrary/16648-part-iv-physical-processes>

**How is soil moisture initialized in the forecasts? (climatology / realistic / other)** realistic

**If “realistic”, does the soil moisture come from an analysis using the same LSM as is coupled to the GCM for forecasts, or another source? Please describe the process of soil moisture initialization.**

LDAS-based (simplified EKF) as used in all IFS forecast and described here: <https://software.ecmwf.int/wiki/display/LDAS/LDAS+Home>

**Is there horizontal and/or vertical interpolation of initialization data onto the forecast model grid? If so, please give original data resolution(s).** Yes horizontal interpolations. For soil moisture the interpolation is standardized on soil moisture index (to account for different soil texture in input and target resolution grid).

**Does the LSM differentiate between liquid and ice content of the soil? If so, how are each initialized?** Yes in a diagnostic wave using temperature and a latent heat barrier (described in Viterbo et al. 1999, see IFS documentation)

**If all model soil layers are not initialized in the same way or from the same source, please describe.** The LDAS is active on the top 1m of soil moisture (the first 3 layers) and the forth layer (1 to 2,89 m deep) is not initialised.

**How is snow initialized in the forecasts? (climatology / realistic / other)** realistic

**If “realistic”, does the snow come from an analysis using the same LSM as is coupled**

**to the GCM for forecasts, or another source? Please describe the process of soil moisture initialization.** LDAS-based (Optimal Interpolation) as used in all IFS forecast and described here: <https://software.ecmwf.int/wiki/display/LDAS/LDAS+Home>

**Is there horizontal and/or vertical interpolation of data onto the forecast model grid? If so, please give original data resolution(s)** horizontal interpolation

**Are snow mass, snow depth or both initialized? What about snow age, albedo, or other snow properties?** Snow mass and snow temperature are initialized by the LDAS, snow albedo and snow density are cycled from the model forecast (open loop).

**How is soil temperature initialized in the forecasts? (climatology / realistic / other)** realistic

**If "realistic", does the soil moisture come from an analysis using the same LSM as is coupled to the GCM for forecasts, or another source? Please describe the process of soil moisture initialization.** LDAS-based (Optimal Interpolation) as used in all IFS forecast and described here: <https://software.ecmwf.int/wiki/display/LDAS/LDAS+Home>

**Is the soil temperature initialized consistently with soil moisture (frozen soil water where soil temperature  $\leq 0^{\circ}\text{C}$ ) and snow cover (top layer soil temperature  $\leq 0^{\circ}\text{C}$  under snow)?** Both the top soil temperature and the snow temperature (if present) are initialized.

**Is there horizontal and/or vertical interpolation of data onto the forecast model grid? If so, please give original data resolution(s)** horizontal interpolation

**If all model soil layers are not initialized in the same way or from the same source, please describe.** Only the first soil layer temperature is initialized, the other layers are cycled from the model forecast (open loop).

**How are time-varying vegetation properties represented in the LSM? Is phenology predicted by the LSM? If so, how is it initialized?** No, a monthly climatology of vegetation is used

**If not, what is the source of vegetation parameters used by the LSM? Which time-varying vegetation parameters are specified (e.g., LAI, greenness, vegetation cover fraction) and how (e.g., near-real-time satellite observations? Mean annual cycle climatology? Monthly, weekly or other interval?)** Leaf Area Index and Albedo monthly climatology both based on MODIS collection 5

**What is the source of soil properties (texture, porosity, conductivity, etc.) used by the LSM?** FAO dominant soil texture class (as in Van Genuchten, 1980)

**If the initialization of the LSM for re-forecasts deviates from the procedure for forecasts, please describe the differences.** The re-forecasts initialization is based on ERA-

Interim and ERA-Interim/Land datasets, while the real-time forecasts are based on the IFS operational initial conditions of the ENS/EDA systems.

#### 4. Model Uncertainties perturbations:

**Is model physics perturbed?** If yes, briefly describe methods: Stochastic physics in the atmosphere (SPPT and SKEB schemes).

**Do all ensemble members use exactly the same model version?** Same

**Is model dynamics perturbed?** No

**Are the above model perturbations applied to the control forecast?** No

#### 5. Surface Boundary perturbations:

**Perturbations to sea surface temperature?** Yes (5-member ensemble of ocean analyses/re-analyses)

**Perturbation to soil moisture?** Yes (EDA)

**Perturbation to surface stress or roughness?** No (generated by wave model)

**Any other surface perturbation?** No

**Are the above surface perturbations applied to the Control forecast?** NA

**Additional comments**

#### 6. Other details of the models:

**Description of model grid:** Cubic octohedral grid

**List of model levels in appropriate coordinates:** <http://www.ecmwf.int/en/forecasts/documentation-and-support/91-model-levels>

**What kind of large scale dynamics is used?** Spectral semi-lagrangian

**What kind of boundary layer parameterization is used?** Moist EDMF with Klein/Hartmann stratus/shallow convection criteria

**What kind of convective parameterization is used?** Tiedtke 89, Bechtold et al 2004 (QJ)

**What kind of large-scale precipitation scheme is used?**

**What cloud scheme is used?** Tiedtke 91 prognostic cloud fraction

**What kind of land-surface scheme is used?** HTESSEL

**How is radiation parametrized?** [CY43R1Official IFS Documentation](#)

**Other relevant details?**

## 7. Re-forecast Configuration

**Number of years covered:** 20 past years

**Produced on the fly or fix re-forecasts?** On the fly

**Frequency:** Produced on the fly twice a week to calibrate the Monday and Thursday 00Z real-time forecasts. The re-forecasts consists of a 11-member ensemble starting the same day and month as the Thursday real-time forecasts for the past 20 years.

**Ensemble size:** 11 members

**Initial conditions:** ERA interim (T255L60) + Soil reanalysis (Tco639) + ORAS5 ocean initial conditions (0.25 degree)

**Is the model physics and resolution the same as for the real-time forecasts?** Yes

**If not, what are the differences?** NA

**Is the ensemble generation the same as for real-time forecasts?** Yes. Except for EDA perturbations which are taken from the most recent year.

**If not, what are the differences?** NA

**Other relevant informations:**

ECMWF re-forecasts are produced on the fly. This means that every week a new set of re-forecasts are produced to calibrate the Monday and Thursday real-time ensemble forecasts of the following week using the latest version of IFS. The ensemble re-forecasts consist of a 11-member ensemble starting the same day and month as a real-time forecast (Monday and Thursday), but covering the past 20 years. For instance the first re-forecast set archived in the S2S database with this new version of the ECMWF model was the re-forecast used to calibrate the real-time forecast of 14 May 2015 (a Thursday). This set consisted of a 11-member ensemble starting on 1st January 1995, 1st January 1996, ... 1st January 2014 (20 years, 11 member ensemble = 220-member climate ensemble). The re-forecast dataset is therefore updated every week in the S2S archive.

The ECMWF re-forecasts are archived in the S2S database using two dates: "date" and "hdate" (see examples below): hdate is the actual date of the re-forecast (e.g. 19950101) while date is the date of the real-time forecast (=ModelversionDate in grib2) associated to the re-forecast (20150101). The reason we need 2 dates is because the ECMWF re-forecasts are produced on the fly and we need to avoid the re-forecasts produced in the future years to overwrite the re-forecasts currently produced. Therefore ModelversionDate allows us to distinguish the re-forecasts produced in 2015 from those produced in 2016, 2017...

## 8. References:

Comprehensive description of the model physics: [CY43R1 Official IFS Documentation](#)

Description of the extended range forecasts: <http://www.ecmwf.int/en/forecasts/documentation-and-support/extended-range-forecasts>