

Redes Neurais Recorrentes Aplicadas à Previsão de Radiação Solar no Horizonte de Curto Prazo

Eduarth Dapper Heinen¹, Ricardo A. S. Fernandes¹

¹Programa de Pós-Graduação em Ciências da Computação (PPGCC)
Universidade Federal de São Carlos (UFSCAR)
Caixa Postal 676 – 13565-905 – Sao Carlos, SP

eduarth.heinen@dc.ufscar.br, ricardo.asf@ufscar.br

Abstract. *Precise estimates of energy production and consumption are essential to promote the integration of renewable energy sources to the electrical grid, thus reducing fossil fuel consumption and its effects on climate change. In this scenario, many experiments have developed solar radiation forecasting methods, but not so many of those apply Recurrent Neural Networks and their potential of modeling time series. This article reviews some of the models and outlines an experiment using Recurrent Neural Networks to forecast solar radiation. Model performance is evaluated with irradiance data in 5 minutes resolution, from 2014 to 2016. New experiments will be conducted investigating model's adequacy to longer horizons and the effect of data normalization.*

Resumo. *Estimativas precisas da geração e consumo de eletricidade são necessárias para promover a integração de fontes de energia renováveis à malha elétrica, assim reduzindo o consumo de combustíveis fósseis e seus efeitos nas mudanças climáticas. Neste cenário, diversos experimentos têm desenvolvido métodos de previsão de radiação solar, mas poucos destes aplicam Redes Neurais Recorrentes e seu potencial de modelar séries temporais. Este artigo revisa alguns dos modelos e apresenta um experimento utilizando Redes Neurais Recorrentes em previsões de radiação solar. O desempenho do modelo é avaliado em dados de irradiância com resolução de 5 minutos, de 2014 à 2016. Novos experimentos serão conduzidos investigando a adequação do modelo a horizontes mais longos e o efeito da normalização dos dados.*

1. Introdução

Durante as convenções das Nações Unidas sobre Mudanças Climáticas, desde 1992, governantes e membros da comunidade científica discutem as consequências da interferência humana no clima e os impactos econômicos e sociais do controle das emissões. Destas convenções resultaram o Protocolo de Kyoto, o Acordo de Cancún e o Acordo de Paris, sendo este último assinado em dezembro de 2015 na 21ª Conferência das Partes. Este novo acordo estabelece o compromisso de 197 países em controlar o aquecimento da atmosfera. Sua principal meta é impedir que a temperatura média global se eleve em 2°C quando comparada às temperaturas anteriores à revolução industrial [UNFCCC 2015]. O consenso dos membros é de que manter o aquecimento abaixo deste limite deve assegurar produção de alimentos e desenvolvimento econômico compatíveis com o crescimento da população até o final do século XXI [Rogelj et al. 2016].

Desde a Revolução Industrial, a expansão da economia mundial foi impulsionada pela oferta crescente de combustíveis fósseis [Höök and Tang 2013]. Por consequência, aumentaram as emissões decorrentes da produção de eletricidade e do transporte à combustão, responsáveis por três-quartos das emissões globais de CO₂ em 2014 [IEA 2016a]. Tendo em vista a forte correlação entre o aquecimento recente da atmosfera e as emissões antropogênicas [Pachauri et al. 2014], fica evidente a necessidade de renovar os métodos de geração de energia para o controle das mudanças climáticas.

Substituir combustíveis fósseis por fontes de energia renováveis (FER) é parte fundamental deste processo. A extensa adoção de FER ainda encontra obstáculos no custo nivelado de eletricidade (LCOE) e na integração de fontes variáveis, como a fotovoltaica e eólica, aos sistemas elétricos existentes. Mas em contrapartida, promove benefícios sociais e econômicos, amplo acesso à eletricidade, segurança energética e reduzidos impactos ambientais [Edenhofer et al. 2011].

Entre 2010 e 2015 o custo de instalação de equipamentos fotovoltaicos diminuiu 40 à 75%. A capacidade fotovoltaica instalada, equivalente a 225 GW em 2014, cresceu 49 GW em 2015, 70 GW a 75 GW em 2016, e estima-se que ainda triplicará até 2020 [IEA 2016b, IEA 2017]. Ainda assim, o LCOE – proporção entre produção estimada e investimento ao longo da vida útil – de instalações fotovoltaicas ainda é superior ao de hidroelétricas, termoelétricas modernas e usinas à gas com turbinas de ciclo combinado [IEA 2016b].

Adotar FER em larga escala também aumenta a complexidade de operação dos sistemas elétricos, pois torna-se necessário estimar e responder aos ciclos e flutuações destes recursos. Manter o suprimento de energia sem restringir a produção renovável requer capacidade de: acionar usinas de apoio, unidades de armazenamento ou transferir eletricidade de outras regiões durante os períodos improdutivos; controlar outras usinas para que acompanhem a variação das fontes renováveis, por exemplo, reduzindo o desempenho das hidroelétricas nos momentos de maior potencial fotovoltaico; e ampliar a capacidade em épocas de alta disponibilidade, pois devido à intermitência e variabilidade destes recursos uma vasta estrutura de geração é necessária [IEA 2016b].

Conforme aumenta a parcela de fontes renováveis no suprimento de energia torna-se imperativo estimar com precisão a geração e consumo de eletricidade. Previsões em horizontes distintos reduzem as incertezas e auxiliam a operação dos sistemas. Estimativas dias à frente, por exemplo, permitem alocar usinas e reservas de energia capazes de suprir a demanda de uma cidade ou região, assim como estimativas em horizontes de 1 à 6 horas alertam para flutuações da produção e permitem tomar medidas para evitar a interrupção do suprimento.

Considerando as limitações mencionadas e a busca por modelos de previsão apurados, este artigo descreve um experimento que realiza previsões de curtíssimo prazo (5 minutos à frente) da irradiância solar incidente. Assim, a Seção 2 descreve alguns modelos de previsão semelhantes. A Seção 3 apresenta os dados utilizados e as tarefas de pré-processamento e seleção de variáveis realizadas. Na Seção 4 é apresentada a metodologia proposta. Por fim, a Seção 5 destina-se a apresentar as conclusões parciais e as diretrizes futuras do experimento.

2. Revisão da Literatura

Motivados pela operação eficiente dos sistemas elétricos de potência, alguns grupos de pesquisa têm se dedicado à previsão da radiação solar e produção fotovoltaica para distintos horizontes, localidades e extensões geográficas. Estes experimentos podem ser divididos em três categorias: métodos de Persistência presumem que parte das condições se sustenta entre a última leitura e o horizonte de previsão; métodos de Regressão Estatística realizam previsões por meio da análise de séries temporais; e técnicas de Aprendizado de Máquina, como Redes Neurais Artificiais e Regressão por Vetores de Suporte (SVR), produzem estimativas de acordo com os relacionamentos inferidos dos exemplos de treino.

Métodos de persistência são frequentemente utilizados como parâmetro de comparação de resultados em relação a outras técnicas propostas. Devido à sua simplicidade, são exemplares da relação entre complexidade do modelo e precisão das estimativas. Assim, a aplicação de métodos mais complexos só é justificada caso supere o desempenho dos modelos de persistência. Suas versões mais simples, chamadas *naive persistence*, assumem que os valores se sustentam entre a última leitura e o horizonte de previsão. Técnicas de *smart persistence*, por outro lado, incluem a persistência dos índices de céu claro e de clareza. Índices que se referem a proporção entre estimativas de irradiância em condições atmosféricas ideais (modelos de céu claro ou irradiância no topo da atmosfera) e os valores observados a nível do solo, de modo que descrevem a atenuação causada pelas condições atmosféricas. As estimativas do modelo de persistência dos Índices de Céu Claro correspondem à estimativa de irradiância em condições ideais, em proporção da atenuação na última observação. Nos testes realizados por Inman et al. (2013) em horizontes de 1h, o modelo alcançou erro absoluto (e_{abs}) inferior à 0.1 em dias predominantemente ensolarados, contudo em dias nublados, variou entre 0.2 e 0.5.

Ainda deve-se citar a *ramp persistence*, que produz estimativas considerando que a diferença na produção entre as duas últimas leituras se repete entre a observação mais recente e o horizonte de previsão. Como também a persistência de velocidade de nuvens, que cria mapas de desempenho dos painéis fotovoltaicos, deslocados de acordo com a movimentação das nuvens. Estas técnicas, utilizadas em conjunto por Lipperheide et al. (2015) em estimativas de desempenho em uma usina fotovoltaica, alcançaram nRMSE (do inglês *normalized root mean squared error*) entre 2,7% e 7,3% em horizontes de 20 a 60 segundos.

Experimentos de regressão estatística, por sua vez, incluem o estudo realizado por Boland (2008). Este analisa a periodicidade de uma série temporal de irradiância solar e aplica um modelo preditivo em horizontes de 1 hora e 1 dia a frente. Após remover a sazonalidade anual e diária dos dados, estabelecidas pela transformada de Fourier da série temporal, o modelo auto-regressivo (AR) proposto pelos autores alcança resultados de nRMSE 23.3% em horizontes de 1h.

Modelos ARMA combinam modelos auto-regressivos (AR) e de médias móveis (MA, do inglês *moving average*) e são vastamente utilizados em estimativas de energia renovável. O experimento dirigido por David et al. 2016, por exemplo, aplica modelos ARMA e GARCH (do inglês, *generalized autoregressive conditional heteroskedasticity*) para estimar irradiância global horizontal em frequências de 10 minutos à 1 hora e dados provenientes de 6 localizações. Após normalizar os dados em razão do índice de céu claro, removendo os ciclos diário e anual, os autores aplicam três métodos predi-

tivos: um *ensemble* de modelos de persistência; um modelo ARMA combinado a um algoritmo RLS (*Recursive Least Squares*) que determina recursivamente os coeficientes de regressão; e um modelo GARCH que associa faixas de confiança às previsões do modelo ARMA de acordo com variabilidade dos erros anteriores, produzindo estimativas probabilísticas. Comparando os resultados médios entre todas as localidades, os modelos de persistência obtêm nRMSE entre 22.3 e 32.5% e MAE (em proporção da irradiância média global) entre 12 e 20.9% para horizontes de 10 a 60 minutos, enquanto o modelo ARMA recursivo alcança nRMSE entre 20.8 e 30.3% e MAE entre 12.5 e 21.4% nos mesmos horizontes. As previsões do modelo GARCH são avaliadas por CPRS (*Continuous Ranked Probability Score*), que considera a precisão das estimativas pontuais e a confiabilidade dos intervalos, com resultados entre 9.5 e 15.2%.

O estudo dirigido por Voyant et al. (2013), por sua vez, compara o desempenho de modelos ARMA (do inglês *autoregressive moving average*), da arquitetura de redes neurais *Multilayer Perceptron* (MLP) e de um modelo híbrido MLP+ARMA. Além disso, avalia o efeito da remoção da sazonalidade dos dados, especificamente a normalização por índices de céu claro e de claridade, e a combinação destes com médias móveis. Argumentando que uma metodologia uniforme de avaliação é necessária para comparar experimentos distintos, os autores propõem: testar os modelos em longos períodos e localizações distintas, utilizar RMSE (do inglês *root mean squared error*) e nRMSE como indicadores de performance, analisar a taxa de erro a cada estação individualmente e comparar os resultados com modelos de persistência, como exemplares da proporção entre precisão e complexidade dos modelos. Os melhores resultados apresentados são de nRMSE 23.4% do MLP aplicado à média diária, 27.3% do MLP em estimativas da irradiância 24h à frente, 14.9% do modelo MLP+ARMA em horizontes de 1h e 20.2% do MLP em estimativas 5 minutos à frente [Voyant et al. 2013].

Redes Neurais Artificiais também foram empregadas na análise comparativa de Pedro e Coimbra (2012), assim como métodos de persistência, modelo ARIMA (do inglês *autoregressive integrated moving average*), k-NN (do inglês *k-nearest neighbors*) e RNA otimizada por algoritmos genéticos. Utilizando somente informações locais, os modelos produzem estimativas da geração de energia elétrica de uma usina na Califórnia, em horizontes 1 e 2 horas à frente. Para remover a sazonalidade dos dados sem recorrer à informações meteorológicas foi elaborado um mapa tridimensional da produção através dos anos, de maneira que sua superfície representa a expectativa de produção média a cada instante. Normalizar as leituras em razão desta expectativa remove os ciclos determinísticos anual e diário da radiação solar, restando somente a variação causada pelas condições meteorológicas. Ao final dos testes, os resultados em horizontes de 1 e 2 horas foram: modelos de persistência alcançaram nRMSE de 19,27% e 28,86%, o modelo ARIMA obteve 18,95% e 25,89%, o modelo k-NN 20,90% e 29,14%, a RNA treinada com o algoritmo de Levenberg-Marquardt atingiu nRMSE de 15,82% e 25,61%, e a RNA otimizada com algoritmo genético obteve os melhores resultados com 13,07% e 18,71% [Pedro and Coimbra 2012].

3. Conjunto de Dados e Seleção de Atributos

O *Solar Radiation Monitoring Laboratory* (SRML) da *University of Oregon* disponibiliza um conjunto de dados contendo observações de radiação solar, variáveis meteorológicas e produção fotovoltaica de um conjunto de painéis com capacidade de 1,2 kW em Portland

(45°N, 122°O). Informações horárias da cobertura do céu, provenientes do Aeroporto de Portland, são disponibilizadas pelo *National Oceanic and Atmospheric Administration*.

Da união dos dados de irradiância e cobertura do céu foram produzidos dois conjuntos de dados, contendo 15 e 30 minutos de observações. Este processo consistiu em remover as leituras ausentes e o período noturno (entre 19h e 5h), e concatenar sequências de 15 e 30 minutos de observações à irradiância global horizontal 5 minutos a frente. Do conjunto de treinamento, entre 1° de janeiro de 2014 e 31 de dezembro de 2015, foram removidas 2,9% das 120.498 leituras. O conjunto de validação, por sua vez, possuía observações dos meses de julho e dezembro de 2016, contendo 10.246 leituras das quais 1,7% foram removidas. Ambos os conjuntos foram normalizados removendo leituras acima do 3° quartil e abaixo do 1°, centralizando os valores em média 0 e reduzindo a escala das leituras para que estivessem contidas entre $[-1, 1]$.

Métodos de seleção de atributos da ferramenta Weka [Hall et al. 2009] foram utilizados para eleger os atributos mais relevantes na previsão da irradiância global horizontal. A Tabela 1 apresenta os 10 primeiros resultados para os conjuntos com observações de 15 e 30 minutos de duração. Apesar dos resultados divergirem alguns atributos se repetem de maneira consistente, como as irradiâncias direta, difusa e global horizontal, a cobertura do céu, o dia e o horário. Quanto aos períodos, a leitura mais recente (t_{0-1}) aparenta possuir maior relevância, mas supõe-se que o horizonte de previsão (5 minutos) seja fator determinante deste resultado. Dia e Horário carregam informações sobre os ciclos anual e diário da radiação solar, entretanto, estes podem ser removidos normalizando os dados em proporção da Irradiância em Céu Claro, como sugerido por Inman et al. (2013).

CFS Subset	RelieFF	PCA
- 15 minutos -		
Irrad. Global Horiz. t_{0-1}	Irrad. Direta t_{0-1}	Horário t_{0+1}
Cobertura do Céu t_{0-3}	Irrad. Difusa t_{0-1}	Dia t_{0-2}
Voltagem (painel 30°) t_{0-1}	Irrad. Direta t_{0-2}	Cobertura do Céu t_{0-3}
Voltagem (painel 15°) t_{0-1}	Irrad. Direta t_{0-3}	Horário t_{0-2}
Dia	Irrad. Difusa t_{0-3}	Irrad. Difusa t_{0-2}
	Irrad. Difusa t_{0-2}	Irrad. Global Horiz. t_{0-2}
	Cobertura do Céu t_{0-1}	Temperatura (painel 30°#6) t_{0-3}
	Cobertura do Céu t_{0-2}	Temperatura (painel 30°#5) t_{0-3}
	Cobertura do Céu t_{0-3}	Temperatura (painel 30°#4) t_{0-3}
	Horário t_0	Temperatura (painel 30°#3) t_{0-3}
- 30 minutos -		
Irrad. Global Horiz. t_{0-1}	Irrad. Direta t_{0-1}	Horário t_{0+1}
Cobertura do Céu t_{0-6}	Irrad. Direta t_{0-2}	Cobertura do Céu t_{0-5}
Voltagem (painel 30°) t_{0-1}	Irrad. Difusa t_{0-1}	Dia
	Irrad. Direta t_{0-3}	Temperatura (painel 30°#6) t_{0-5}
	Irrad. Direta t_{0-4}	Temperatura (painel 30°#3) t_{0-5}
	Irrad. Direta t_{0-6}	Temperatura (painel 30°#5) t_{0-5}
	Irrad. Direta t_{0-5}	Horário t_{0-4}
	Irrad. Difusa t_{0-2}	Irrad. Global Horiz. t_{0-4}
	Irrad. Global (painel 30°) t_{0-1}	Irrad. Direta t_{0-4}
	Irrad. Difusa t_{0-6}	Irrad. Difusa t_{0-4}

Tabela 1. Atributos com melhor classificação de acordo com o método de seleção.

4. Experimento

Redes Neurais Artificiais *Feedforward*, como o MLP, são formadas por neurônios organizados em camadas e conectados de maneira que a informação percorra a rede partindo da camada de entrada, através das camadas *hidden*, até alcançar a camada de saída. Redes Recorrentes possuem a mesma arquitetura, entretanto o estado da rede é armazenado ao final de cada iteração e reinserido ao início da iteração seguinte. Desta forma, são capazes de armazenar informações sobre os exemplos anteriores e assim distinguir correlações temporais entre as observações [Pascanu et al. 2013, Bengio et al. 2013].

Utilizando um modelo de Rede Neural Recorrente da biblioteca *Tensorflow*, foram realizados 2 experimentos: no primeiro, o modelo foi treinado com dados entre 1º de janeiro de 2014 e 31 de dezembro de 2015 contendo 6 leituras de irradiância global horizontal (30 minutos), cobertura do céu, data e horário no horizonte de previsão; no segundo, foram utilizados os mesmos atributos, porém com somente 3 observações de irradiância (15 minutos).

Em ambos os experimentos, a Rede Neural Recorrente é composta de uma camada oculta contendo 18 neurônios (configuração que obteve os melhores resultados) e apenas um neurônio de saída, referente a irradiância global horizontal estimada 5 minutos a frente. O algoritmo de aprendizado *RMSProp* foi aplicado junto da função de ativação *softsign*. Como parâmetros de desempenho foram utilizados MAE (do inglês, *Mean Absolute Error*) e nRMSE, descritos na Equação 1. Visto que diferentes autores utilizam parâmetros distintos, é importante ressaltar que neste experimento nRMSE corresponde à normalização do RMSE (do inglês, *Root Mean Squared Error*) em proporção da irradiância global média no período [Voyant et al. 2017].

A precisão do modelo foi inicialmente avaliada em estimativas dos dias 12 à 15 de julho e 11 à 14 de dezembro de 2016. Alcançando nRMSE de 50,1% e 123,1% com 15 minutos de observações e 68,0% e 128,6% com 30 minutos, respectivamente a cada período. A comparação entre estimativas e valores observados, associada aos valores de cobertura do céu, é apresentada na Figura 1.

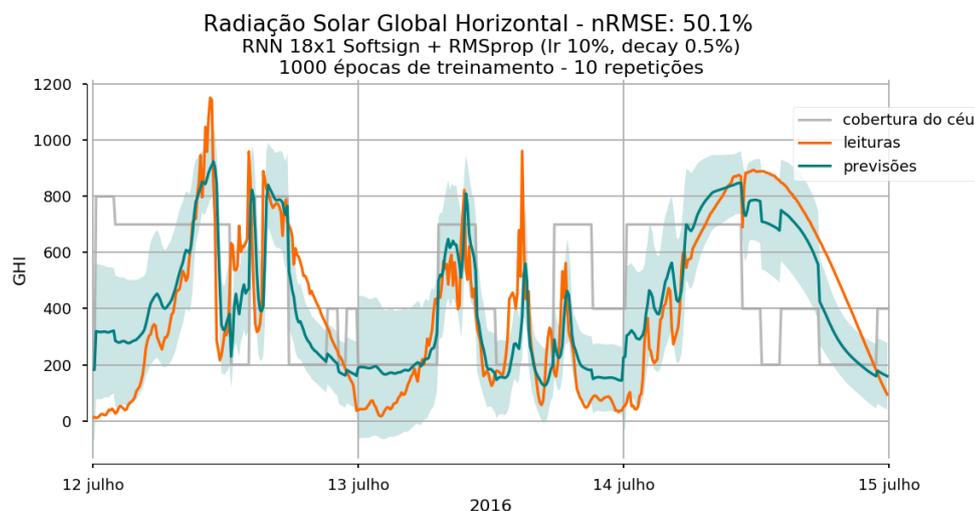


Figura 1. Comparação entre estimativa média em 10 iterações do modelo e irradiância observada no período de 12 à 15 de julho de 2016.

O erro das estimativas no início e fim dos dias levou a considerar períodos mais restritos ou mais extensos, com a suposição de que isso possa gerar melhores resultados. Para investigar esta hipótese, dois novos conjuntos foram produzidos, contendo somente observações entre 7h00 e 18h00, e observações das 24 horas do dia, incluindo os valores nulos durante a noite. O desempenho do modelo melhorou pela remoção de leituras da manhã e início da noite, alcançando nRMSE 35.7% em julho e 100.3% em dezembro, porém foram descartados períodos produtivos.

Um último experimento foi realizado avaliando o nRMSE e o MAE das estimativas através de todo o ano 2016. Os resultados são apresentados pela Tabela 2.

Conjunto de Dados	nRMSE (%)	MAE (W/m^2)
GHI 15 min. e Cobertura do Céu – entre 5 e 19h	83.76	146.56
GHI 30 min. e Cobertura do Céu – entre 5 e 19h	78.25	139.95
GHI 15 min. e Cobertura do Céu – entre 7 e 18h	68.79	156.4

Tabela 2. Desempenho do modelo através do ano 2016.

$$MAE = \frac{1}{N} \times \sum_{i=1}^N |\hat{y}_i - y_i|$$

$$nRMSE = \frac{\sqrt{\frac{1}{N} \times \sum_{i=1}^N (\hat{y}_i - y_i)^2}}{\tilde{y}}$$

Equação 1. MAE e nRMSE, assumindo \hat{y}_i e y_i como estimativa e leitura no momento i , e \tilde{y} como a irradiância global média no período.

5. Trabalho Futuro

É necessário avaliar o efeito da remoção dos ciclos determinístico anual e diário da radiação solar, como a normalização pelos índices de céu claro e clareza, analisadas por Inman et al. (2013). As observações de cobertura do céu também devem ser substituídas por estimativas de NWP, imagens de satélite ou outro atributo com maior confiabilidade e resolução temporal. Apesar da Rede Neural Recorrente ter modelado a influência das alterações na nebulosidade, como pode ser observado na Figura 1, estas não refletem necessariamente no aumento ou diminuição dos valores previstos. O conjunto de dados também deve ser redimensionado pelas médias ou totais de radiação em intervalos de 15, 30, 60 e 120 minutos, para avaliar o modelo em horizontes mais longos. O desempenho do modelo também será avaliado com conjuntos de dados provenientes de outras localizações. Novos métodos devem ser explorados, como LSTM, assim como é necessário estabelecer um modelo de permanência como parâmetro de comparação. Considerando que Redes Neurais Recorrentes são bastante afetadas por problemas como *vanishing* e *exploding gradient*, métodos de controle do gradiente e outros algoritmos de aprendizado devem ser investigados.

Referências

- Bengio, Y., Boulanger-Lewandowski, N., and Pascanu, R. (2013). Advances in optimizing recurrent networks. In *Acoustics, Speech and Signal Processing (ICASSP), 2013 IEEE International Conference on*, pages 8624–8628. IEEE.
- Boland, J. (2008). Time series modelling of solar radiation. *Modeling Solar Radiation at the Earth's Surface, Springer Verlag*, pages 283–312.
- David, M., Ramahatana, F., Trombe, P.-J., and Lauret, P. (2016). Probabilistic forecasting of the solar irradiance with recursive arma and garch models. *Solar Energy*, 133:55–72.
- Edenhofer, O., Pichs-Madruga, R., Sokona, Y., Seyboth, K., Kadner, S., Zwickel, T., Eickemeier, P., Hansen, G., Schlömer, S., von Stechow, C., et al. (2011). *Renewable energy sources and climate change mitigation: Special report of the intergovernmental panel on climate change*. Cambridge University Press.
- Hall, M., Frank, E., Holmes, G., Pfahringer, B., Reutemann, P., and Witten, I. H. (2009). The weka data mining software: an update. *ACM SIGKDD explorations newsletter*, 11(1):10–18.
- Höök, M. and Tang, X. (2013). Depletion of fossil fuels and anthropogenic climate change—a review. *Energy Policy*, 52:797–809.
- IEA (2016a). CO₂ Emissions from Fuel Combustion.
- IEA (2016b). World energy outlook 2016.
- IEA (2017). Tracking clean energy progress 2017.
- Inman, R. H., Pedro, H. T., and Coimbra, C. F. (2013). Solar forecasting methods for renewable energy integration. *Progress in energy and combustion science*, 39(6):535–576.
- Lipperheide, M., Bosch, J., and Kleissl, J. (2015). Embedded nowcasting method using cloud speed persistence for a photovoltaic power plant. *Solar Energy*, 112:232–238.
- Pachauri, R. K., Allen, M. R., Barros, V. R., Broome, J., Cramer, W., Christ, R., Church, J. A., Clarke, L., Dahe, Q., Dasgupta, P., et al. (2014). *Climate change 2014: synthesis report. Contribution of Working Groups I, II and III to the fifth assessment report of the Intergovernmental Panel on Climate Change*. IPCC.
- Pascanu, R., Mikolov, T., and Bengio, Y. (2013). On the difficulty of training recurrent neural networks. In *International Conference on Machine Learning*, pages 1310–1318.
- Pedro, H. T. and Coimbra, C. F. (2012). Assessment of forecasting techniques for solar power production with no exogenous inputs. *Solar Energy*, 86(7):2017–2028.
- Rogelj, J., Den Elzen, M., Höhne, N., Fransen, T., Fekete, H., Winkler, H., Schaeffer, R., Sha, F., Riahi, K., and Meinshausen, M. (2016). Paris agreement climate proposals need a boost to keep warming well below 2 c. *Nature*, 534(7609):631–639.
- UNFCCC (2015). Adoption of the paris agreement. *Conference of the Parties, Twenty-first session*.
- Voyant, C., Notton, G., Kalogirou, S., Nivet, M.-L., Paoli, C., Motte, F., and Fouilloy, A. (2017). Machine learning methods for solar radiation forecasting: A review. *Renewable Energy*, 105:569–582.

Voyant, C., Paoli, C., Muselli, M., and Nivet, M.-L. (2013). Multi-horizon solar radiation forecasting for mediterranean locations using time series models. *Renewable and Sustainable Energy Reviews*, 28:44–52.