



LISBON
SCHOOL OF
ECONOMICS &
MANAGEMENT
UNIVERSIDADE DE LISBOA

MESTRADO EM
GESTÃO DE SISTEMAS DE
INFORMAÇÃO

TRABALHO FINAL DE MESTRADO
PROJETO

*OBJETIVOS DE DESENVOLVIMENTO
SUSTENTÁVEL: PREVISÃO DO PROGRESSO DE
PORTUGAL NO CUMPRIMENTO DA AGENDA 2030*

LEONOR CORREIA MARTINS COSTA LOPES

OUTUBRO – 2020

MESTRADO EM
GESTÃO DE SISTEMAS DE
INFORMAÇÃO

TRABALHO FINAL DE MESTRADO
PROJETO

*OBJETIVOS DE DESENVOLVIMENTO
SUSTENTÁVEL: PREVISÃO DO PROGRESSO DE
PORTUGAL NO CUMPRIMENTO DA AGENDA 2030*

LEONOR CORREIA MARTINS COSTA LOPES

ORIENTAÇÃO:

PROFESSOR DOUTOR CARLOS COSTA

OUTUBRO – 2020

Agradecimentos

Para começar gostaria de deixar um agradecimento a todos os professores que se cruzaram comigo neste percurso tão prazeroso no mestrado de Gestão de Sistemas de Informação, que contribuíram para a minha aprendizagem e crescimento tanto a nível profissional como a nível pessoal. Devo destacar e fazer um agradecimento mais especial ao professor Carlos Costa que não hesitou em aceitar orientar a minha dissertação, demonstrando sempre apoio e auxílio quando mais precisei.

Agradecer a todos os colegas que me acompanharam neste percurso académico, aos meus amigos por me motivarem e nunca me deixarem duvidar de que iria concluir esta etapa com sucesso.

Por fim, mas não menos importante agradecer à minha família em especial aos meus pais que me proporcionaram todas as oportunidades para que concretizasse os meus sonhos sem nunca hesitarem. A eles, estarei sempre grata.

Obrigada!

Resumo

O mundo como o conhecemos irá mudar caso não façamos nada para o impedir. Apela-se cada vez mais a uma maior consciencialização das populações alertando-as para a adoção de comportamentos mais sustentáveis. Sustentáveis não só a nível ambiental como também ao nível social e económico para que, sem exclusões, contribuamos para a mudança que deve ser feita.

A dissertação procura analisar e avaliar o comportamento de um conjunto de indicadores de sustentabilidade em Portugal de forma a perceber enquanto país, se estão a ser tomadas as decisões e as estratégias mais acertadas para contribuir para um planeta mais sustentável. Para essa avaliação será desenvolvido para cada um dos indicadores selecionados um modelo de previsão tendo como base os dados registados até ao ano de 2019. Para o seu desenvolvimento vai ser seguida uma abordagem de aprendizagem automática que se espera que auxilie na resolução do objetivo proposto.

Os resultados do trabalho desenvolvido permitiram concluir que apesar dos desafios inerentes, Portugal está comprometido e num bom caminho para contribuir para um mundo mais sustentável.

Palavras-Chave: Sustentabilidade; Objetivos de Desenvolvimento Sustentável; Séries Temporais; Previsão; Aprendizagem Automática

Abstract

The world as we all know will change in case we did not do anything to stop it. There is an increasing call for the awareness of populations by alerting them to adopt more sustainable behaviours. Not only at the environmental level but also at the social and economic level so that, without exclusions, we contribute to the change that must be made. The dissertation seeks to analyse and evaluate the behaviour of a set of sustainability indicators in Portugal to understand, as a country, if the measures and strategies implemented have been the most appropriate to contribute for a more sustainable planet. To make that evaluation will be developed for each one of the selected indicators a forecast model having into account all recorded data until the year of 2019. For its development will be followed a machine learning approach, which is expected to help in the resolution of the proposed objective. The results of the developed work allowed to conclude that despite the challenges, Portugal is committed and on track to contribute for a more sustainable world.

KeyWords: Sustainability; Sustainable Development Goals; Time Series; Forecast; Machine Learning

Índice

Agradecimentos	i
Resumo	ii
Abstract	iii
Índice	iv/v
Lista de Figuras	vi
Lista de Tabelas	vi/vii
Lista de Siglas e Abreviaturas	viii
1. Introdução	1
1.1 Contextualização do Problema	1
1.2 Questão de Investigação	2
1.3 Objetivos	2
1.4 Abordagem Metodológica	2
1.5 Estrutura da Dissertação	3
2. Revisão de Literatura	4
2.1 Sustentabilidade	4
2.2 Objetivos de Desenvolvimento Sustentável – ODS	5
2.3 Previsão de séries temporais e as suas diferentes abordagens	6
2.3.1 Abordagens Estatísticas	7
8	
2.3.2 Abordagem de Aprendizagem Automática - Redes Neurais	8
2.3.3 Seleção da Abordagem	9
2.3.4 Estudos desenvolvidos com recurso à abordagem LSTM	10
3. Descrição do Trabalho Empírico	11
3.1 Justificação da escolha dos Objetivos de Desenvolvimento Sustentável	11
3.2 Situação atual de Portugal no cumprimento da Agenda 2030	12
3.3 Seleção da linguagem de programação	12
3.4 Estrutura do Framework dos Objetivos de Desenvolvimento Sustentável	13
3.4.1 Indicadores da Organização das Nações Unidas (ONU)	13
3.4.2 Indicadores da União Europeia (UE)	14
3.4.3 Seleção do Framework	15
16	
3.5 Exploração do Dataset	19
3.6 Desenvolvimento do Modelo	22
3.7 Avaliação do Desempenho	24
4 Resultados	26

Índice

4.1	ODS 4 - Educação de Qualidade	26
4.2	ODS 5 - Igualdade de Género	27
4.3	ODS 9 - Indústria, Inovação e Infraestruturas	28
4.4	ODS 10 - Redução das Desigualdades	29
4.5	ODS 13 – Ação Climática	30
4.6	ODS 14 - Proteção da Vida Marinha	31
5	Conclusões	32
6	Limitações	33
7	Trabalhos Futuros	34
8	Referências	34
9	Anexos	38
	Anexo 1: Exemplo ficheiro CSV importado	38
	Anexo 2: Exemplo Gráfico Evolutivo da Previsão	38
	Anexo 3: Evolução do histórico de dados do ODS 4	39
	Anexo 4: Evolução do histórico de dados do ODS 5	39
	Anexo 5: Evolução do histórico de dados do ODS 9	39
	Anexo 6: Evolução do histórico de dados do ODS 10	40
	Anexo 7: Evolução do histórico de dados do ODS 13	40
	Anexo 8: Evolução do histórico de dados do ODS 14	40

Lista de Figuras

Figura 1: Ficheiro CSV – indicador 4.1 (ODS 4)	38
Figura 2: Gráfico Evolutivo – indicador 4.1 (ODS 4)	38

Lista de Tabelas

Tabela I: Descrição de diferentes abordagens estatísticas para previsão de série temporais	8
Tabela II: Descrição de diferentes Redes Neurais para previsão de séries temporais	9
Tabela III: Glossário ODS 4	15
Tabela IV: Glossário ODS 5	16
Tabela V: Glossário ODS 9	17
Tabela VI: Glossário ODS 10	17
Tabela VII: Glossário ODS 13	18
Tabela VIII: Glossário ODS 14	19
Tabela IX: Descrição das bibliotecas utilizadas, mais relevantes, para desenvolvimento do modelo	20
Tabela X: Descrição das classes utilizadas, mais relevantes, para desenvolvimento do modelo	20
Tabela XI: Resultados à análise de desempenho de cada modelo	25
Tabela XII: Resultados dos indicadores do ODS 4	26
Tabela XIII: Resultados dos indicadores do ODS 5	27
Tabela XIV: Resultados dos indicadores do ODS 9	28
Tabela XV: Resultados dos indicadores do ODS 10	29
Tabela XVI: Resultados dos indicadores do ODS 13	30

Tabela XVII: Resultados dos indicadores do ODS 14	31
Tabela XVIII: Evolução do histórico de dados dos indicadores do ODS 4	39
Tabela XIX: Evolução do histórico de dados dos indicadores do ODS 5	39
Tabela XX: Evolução do histórico de dados dos indicadores do ODS 9	39
Tabela XXI: Evolução do histórico de dados dos indicadores do ODS 10	40
Tabela XXII: Evolução do histórico de dados dos indicadores do ODS 13	40
Tabela XXIII: Evolução do histórico de dados dos indicadores do ODS 14	40

Lista de Siglas e Abreviaturas

ARIMA – *Auto Regressive Integration Model*

CRISP-DM – *Cross Industry Standard Process for Data Mining*

CSV – *Comma Separated Values*

EEE – Espaço Económico Europeu

HFCs – Hidrofluorcarboneto

IAEG – *Inter-Agency and Expert Group*

LSTM – *Long Short Term Modeling*

MAE – *Mean Absolute Error*

MAPE – *Mean Absolute Percentage Error*

MSE – *Mean Squared Error*

OCDE – Organização para a Cooperação e Desenvolvimento Económico

ODS – Objetivo de Desenvolvimento Sustentável

ONU – Organização das Nações Unidas

PIB – Produto Interno Bruto

RMSE – *Root Mean Squared Error*

RNN – *Recurrent Neural Network*

UE – União Europeia

1. Introdução

1.1 Contextualização do Problema

Em 2016, uma em cada 8 pessoas vivia em situação de extrema pobreza no mundo. Quase um milhão passava fome, os nascimentos de crianças até aos cinco anos sem registo atingiam um quarto das mesmas, as mulheres despendiam até 2,4 vezes mais tempo que os homens nas tarefas domésticas. Mais de um bilião de pessoas vivia sem condições básicas de eletricidade e de acesso a água potável (United Nations, 2016). A necessidade de agir urgentemente para combater as fragilidades, diferenças e injustiças existentes no planeta levou ao estabelecimento, no dia 25 de setembro de 2015, de uma agenda universal, a cumprir até 2030, assente em 17 objetivos de desenvolvimento sustentável (ODS) e 169 metas a implementar por todos os países.

Trata-se, sem dúvida, de um desafio ambicioso que não caberá apenas aos Governos estabelecer novas estratégias e métricas, será um esforço conjunto entre entidades públicas e privadas, parceiros, organizações não-governamentais, e até da própria população.

Portugal sendo um dos países que se comprometeu a cumprir a Agenda, teve um papel ativo no desenvolvimento da mesma, defendendo que deve ser feito um acompanhamento contínuo do compromisso assumido pelos países.

De acordo com o relatório “*Measuring Distance to the SDG Targets*” lançado pela Organização para a Cooperação e Desenvolvimento Económico (OCDE) em 2019, Portugal «está longe de atingir as 169 metas estabelecidas dos ODS, tendo até ao momento atingido apenas 11», estando abaixo da média do número de metas alcançadas pelos restantes países avaliados. É apresentada como principal razão para esta diferença a dificuldade no acesso aos dados tornando a monitorização menos eficaz.

Outro problema identificado é a sensibilização da população portuguesa e das empresas para os ODS. Em 2017 a *Pricewaterhouse Coopers (PwC)* apresentou “*Os desafios das empresas portuguesas na priorização dos ODS e no relato não financeiro*” onde são indicados quais os objetivos mais priorizados pelas empresas e pelos cidadãos e, segundo o mesmo não existe um único objetivo comum entre ambos pelo que um dos

principais desafios poderá estar relacionado com a criação de medidas e estratégias que consigam ir ao encontro das necessidades da comunidade como um todo.

1.2 Questão de Investigação

Tendo em conta o problema apresentado, a questão de investigação que irá servir de base ao trabalho é:

“Írá Portugal conseguir cumprir a Agenda 2030?”

1.3 Objetivos

O principal objetivo da dissertação é compreender em que patamar estará Portugal, em 2030, no cumprimento das metas estabelecidas para cada um dos ODS. Foram definidos objetivos específicos que irão auxiliar o objetivo principal, sendo eles:

- i. Identificação e comparação de diferentes abordagens de previsão de séries temporais;
- ii. Identificação dos ODS prioritários para Portugal;
- iii. Proposta de modelo de previsão para os ODS;
- iv. Avaliação dos resultados dos modelos de previsão desenvolvidos.

1.4 Abordagem Metodológica

A abordagem escolhida para a realização da dissertação e que será seguida ao longo da mesma é a Quantitativa, uma vez que se irá basear no tratamento e análise de um conjunto de dados e que irão ser utilizadas ferramentas de ciência de dados para analisar dados futuros com base em histórico de dados. Mais especificamente, foi utilizada uma abordagem baseada no CRIP-DM adaptada ao contexto da ciência de dados (Shearer, 2000, Aparicio & Costa, 2020 e Costa & Aparicio, 2020). Esta é constituída por cinco fases.

A primeira consiste na Seleção da população-alvo. Esta seleção será possível após a identificação do problema que, tendo em conta o apresentado anteriormente, para o trabalho a população em estudo serão os ODS e os indicadores que os compõem uma vez que para a realização da análise são tidos em conta os valores registados nos últimos anos para os mesmos.

Tendo identificada a população segue-se para a segunda grande fase desta abordagem, a Recolha de Dados onde, serão extraídos os dados dos indicadores bem como a realização do tratamento e exploração destes para que estejam prontos para o desenvolvimento de cada um dos modelos. Esta etapa culmina com o desenvolvimento dos modelos necessários.

Finda a etapa anterior, um dos objetivos estará cumprido pois já haverá previsão de valores para 2030 para cada um dos indicadores trabalhados. Posto isto, poderá ser feita uma Análise Quantitativa criteriosa ao desempenho de cada modelo utilizando para tal as métricas adequadas.

Por fim é feita a Análise de Resultados em que são interpretados os valores retornados pelos modelos. É também verificado se foi dada uma resposta ao problema identificado e se os objetivos propostos foram atingidos. A etapa é finalizada com uma reflexão sobre as possíveis limitações do estudo realizado e quais os trabalhos futuros que deste poderão resultar.

1.5 Estrutura da Dissertação

O trabalho encontra-se estruturado tendo em conta os objetivos propostos e de forma a encontrar uma resposta à questão de investigação.

O primeiro capítulo é o da Introdução onde será identificado o problema e, por conseguinte, a questão de investigação e os objetivos que o endereçam.

De seguida é feita a Revisão da Literatura que integra todo o estudo teórico, desde apresentação dos conceitos mais relevantes, à análise das principais técnicas e metodologias para o desenvolvimento de um modelo de previsão de séries temporais.

No terceiro capítulo é descrito o Trabalho Empírico onde é exposto o trabalho de preparação antes da construção de cada modelo, desde a seleção e justificação dos ODS, caracterização mais detalhada dos mesmos e por fim, a seleção da linguagem de programação utilizada. De seguida, são detalhados os passos mais relevantes seguidos para o desenvolvimento de cada modelo.

O capítulo seguinte é a apresentação de Resultados, em que para além dos resultados das previsões gerados pelos modelos para os indicadores são também apresentados os resultados da avaliação de desempenho de cada um.

O quinto, sexto e sétimo capítulos contemplam uma reflexão sobre o que foi desenvolvido e analisado nos capítulos anteriores, limitações do estudo e trabalhos futuros.

2. Revisão de Literatura

Neste capítulo será feita a apresentação dos conceitos mais relevantes para o desenvolvimento do estudo. Será estudada a temática da Sustentabilidade seguindo-se uma análise à importância da utilização de métodos de previsão de séries temporais analisando-se as abordagens mais adequadas.

2.1 Sustentabilidade

É inegável que é um tema que tem sido muito abordado ao longo dos últimos anos. Mas já no século passado se falava nesta temática e nas suas implicações. Desde logo, em 1980 a UNESCO já expressava as suas preocupações com as consequências dos atos das populações. No relatório lançado pela organização, “World Conservation Strategy”, esta alertava a sociedade para o uso indevido de recursos e em como estes veriam o seu tempo de vida útil reduzido caso continuassem a ser utilizados inconsequentemente.

Nos anos seguintes de forma a mostrar preocupação com as consequências ecológicas e sociais das ações humanas vários foram os estudos iniciados. A ONU, é sem dúvida uma das organizações que mais iniciativas tem patrocinado para um desenvolvimento mais sustentável. Em 1987, no relatório da Comissão Mundial sobre Meio Ambiente e Desenvolvimento, vêm propor uma definição para o termo Sustentabilidade afirmando que esta consistia em fornecer as necessidades às populações atuais sem comprometer as das populações futuras. Após esta definição, três dimensões emergiram: ambiental, social e económica.

A dimensão ambiental engloba termos como reciclagem, recursos renováveis e purificação. Todos procuram descrever o modo como é possível melhorar a qualidade do ambiente reduzindo o uso de substâncias prejudiciais, de recursos e de energia. (Glavič and Lukman, 2007)

Para melhor explicar em que consiste a dimensão económica é importante ter em consideração três aspetos: contabilidade ambiental, eco-eficiência e investimentos éticos (Agency et al., 2011). Estes procuram assegurar que as organizações apostam em recursos

que reduzam o impacto nos ecossistemas sem comprometer a sua rendibilidade e qualidade dos seus produtos (Agency et al., 2011).

A dimensão social pretende minimizar as diferenças sociais fornecendo direitos semelhantes a todas as populações (Glavič and Lukman, 2007). Engloba preocupações a nível do emprego, atendendo às suas condições e direitos bem como a nível da igualdade de género (Z. Wang et al., 2017).

2.2 Objetivos de Desenvolvimento Sustentável – ODS

Adotados por todos os países membro das Nações Unidas, em 2015, os Objetivos de Desenvolvimento Sustentável foram criados para procurar fazer face aos desafios urgentes a nível ambiental, económico e político, que se vivem atualmente. Com um total de 17 objetivos definidos, estes estão conectados o que significa que o sucesso de um poderá levar ao sucesso de outro. Por exemplo, para se diminuir os índices de pobreza deve-se procurar medidas de crescimento económico concretas aliadas a um conjunto de necessidades sociais básicas como o acesso à educação e à saúde. Contudo, todas estas ações devem ser realizadas simultaneamente à definição de estratégias para uma melhor proteção do ambiente (United Nations, 2019).

Os países membro têm ao longo dos últimos cinco anos delineado estratégias e priorizado objetivos e, havendo progressos ainda muitos esforços têm que ser concentrados para que se cumpram as metas definidas até 2030.

Os ODS podem ser enquadrados em cinco dimensões diferentes: Pessoas, Prosperidade, Planeta, Paz e Parcerias, sendo que dentro de cada dimensão se encontram os objetivos associados a cada temática.

No que diz respeito às pessoas, propôs-se eliminar com todas as formas de pobreza e erradicar a fome de forma a garantir que toda a população tenha condições para viver num ambiente saudável (United Nations, 2015). Os ODS associados a esta dimensão são: ODS 1 (Erradicar a Pobreza), ODS 2 (Erradicar a Fome); ODS 3 (Saúde de Qualidade) ODS 4 (Educação de Qualidade) ODS 5 (Igualdade de Género) e ODS 6 (Água potável e Saneamento).

Quanto à prosperidade, pretende-se que todas as populações vivam uma vida com condições em harmonia com os progressos económico, social e tecnológico (United Nations, 2015). Os ODS associados a esta dimensão são: ODS 7 (Energias Renováveis e Acessíveis), ODS 8 (Trabalho digno e Crescimento Económico), ODS 9 (Indústria,

Inovação e Infraestruturas) e ODS 10 (Redução das Desigualdades).

No que diz respeito ao planeta, é proposto contribuir para a proteção do ambiente havendo uma maior consciencialização para um consumo e produção sustentáveis e fazendo uma gestão dos recursos naturais atendendo às necessidades das populações num curto e longo prazo (United Nations, 2015). Os ODS associados a esta dimensão são: ODS 11 – Cidades e Comunidades Sustentáveis, ODS 12 (Produção e Consumo Sustentáveis) ODS 13 (Ação Climática), ODS 14 (Proteger a Vida Marinha) e ODS 15 (Proteger a Vida Terrestre).

Propõe-se ainda desenvolver condições para que as sociedades sejam cada vez mais inclusivas, eliminando todo o tipo de violência tornando-as mais livres e mais justas (United Nations, 2015). O ODS associado à dimensão da paz é: ODS 16 (Paz, Justiça e Instituições Eficazes). As parcerias pretendem unir esforços para garantir o cumprimento dos ODS, fomentando o espírito de solidariedade entre os países e entidades não descurando as sociedades mais desfavorecidas (United Nations, 2015). O ODS associado a esta dimensão é o 17 (Parcerias para a Implementação dos Objetivos).

2.3 Previsão de séries temporais e as suas diferentes abordagens

Como forma de acompanhar o mercado, as empresas não devem procurar dar respostas reativas, mas sim proativas, ou seja, devem delinear estratégias no presente para atuar num longo prazo e não para atuar num curto prazo. Posto isto, é importante analisar as tendências atuais para tentar estimar quais serão as futuras recorrendo cada vez mais a métodos de previsão (Smith and Agrawal, 2000).

Para a sua previsão é necessário desenvolver modelos matemáticos adequados que permitam estimar como é feito o processo de geração de dados da série temporal para que, posteriormente, preveja o número de observações futuras pretendidas (Khandelwal et al., 2015).

A criação de previsões e análise de tendências tem um valor cada vez mais reconhecido nas organizações pelo que, o desafio com que se deparam é: quais as técnicas mais adequadas ao negócio e como trabalhar os dados existentes? (Smith and Agrawal, 2000)

A resposta à questão poderia ser simples caso tudo permanecesse constante e sem alterações ao longo dos anos. Contudo, tal não se verifica uma vez que os mercados são

voláteis, as tendências estão sempre em constante mudança e por vezes a informação disponível não é completa ou até mesmo fidedigna. (Siarni-Namini et al., 2018)

Ao longo dos anos foram desenvolvidas várias abordagens e técnicas de previsão de séries temporais sendo que, predominantemente, são utilizadas abordagens estatísticas como *AutoRegressive (AR)*, *Moving Average (MA)*, *Simple Exponential Smoothing (SES)* e ainda *Autoregressive Integrated Moving Average (ARIMA)* (Yan, 2012). Todas as técnicas anteriormente descritas são tradicionais, sendo que técnicas de *Machine Learning*, ou Aprendizagem Automática, têm sido igualmente desenvolvidas introduzindo novas abordagens de previsão de valores temporais futuros, utilizando redes neuronais como por exemplo *Artificial Neural Networks (ANNs)*, *Generalized Regression Neural Networks (GRNNs)*, *Radial Basis Function Networks (RBF)*, *Recurrent Neural Networks (RNNs)* (Yan, 2012) e *Long Short-Term Memory (LSTM)*, sendo esta última uma abordagem baseada nas RNN (Panapongpakorn and Banjerdpongchai, 2019).

Com uma grande variedade de escolhas existentes, torna-se fulcral compreender qual a melhor técnica a seguir consoante os dados disponíveis bem como o período temporal a considerar. Existem prós e contras em ambos os tipos de abordagem, tanto tradicionais como de aprendizagem automática, sendo que na hora de decidir não se trata de selecionar a melhor, mas sim a mais eficiente e a que mais se enquadra aos parâmetros em questão. Para além do dinamismo dos dados, há que ter em consideração o facto de poderem não ser lineares e conterem uma complexa estrutura de auto-correlação (Han, J. H., 2018).

2.3.1 Abordagens Estatísticas

Abordagens estatísticas ou tradicionais são maioritariamente utilizadas para prever séries univariadas, isto é, séries que consistem em observações únicas registadas em períodos temporais iguais. São exemplos desta abordagem, as técnicas de análise de regressão, análise exponencial e ARIMA. (V. Prema and K.U. Rao, 2015) Em baixo, encontra-se uma tabela que apresenta algumas técnicas associadas a esta abordagem.

Tabela I

Descrição de diferentes abordagens estatísticas para previsão de série temporais

Abordagem	Descrição
<i>Auto Regressive Integrated Moving Average (ARIMA)</i>	Introduzida por Box e Jenkins (1976) conjuga duas abordagens já existentes: <i>Auto Regressive</i> e <i>Moving Average</i> . O ARIMA permite que dados não estacionários, ou seja dados que não se mantêm constantes ao longo do tempo, sejam tidos em conta para a previsão de séries temporais (Smith and Agrawal, 2000). Outra vantagem desta abordagem é o facto do seu modelo ser composto por um algoritmo simplificado que lhe permite trabalhar com tecnologias avançadas. (Amin and Hoque, 2019).
<i>Moving Average (MA)</i>	O principal objetivo deste modelo é trabalhar os dados passados para estimar a tendência de uma série temporal (V. Prema and K.U. Rao, 2015)
<i>Simple Exponential Smoothing (SES)</i>	Técnica utilizada para prever séries temporais se uma tendência clara ou sazonalidade definidas (V. Prema and K.U. Rao, 2015)
<i>Double Exponential Smoothing (DES) e Triple Exponential Smoothing (TES)</i>	Ambas as abordagens são uma alternativa ao SES para quando se verifica algum tipo de sazonalidade e/ou tendência nos dados. O que distingue uma abordagem da outra é o número de funções usadas, ou seja, opta-se pela DES quando se acrescenta uma função, e utiliza-se a TES quando são acrescentadas duas funções (V. Prema and K.U. Rao, 2015).

Fonte:Próprio autor

2.3.2 Abordagem de Aprendizagem Automática - Redes Neurais

Quando comparadas com as abordagens estatísticas, as de aprendizagem automática são mais flexíveis e adaptáveis a modelos mais complexos e não têm a necessidade de seguir um modelo específico com requisitos a cumprir (Yan, 2012). De seguida serão apresentados alguns tipos de redes neuronais.

Tabela II

Descrição de diferentes Redes Neurais para previsão de séries temporais

Rede Neuronal	Descrição
<i>Artificial Neural Networks (ANNs)</i>	Abordagem apresentada durante a década de 80, muito utilizada por reconhecer e prever a sazonalidade numa série temporal (Khandelwal et al., 2015)
<i>Seasonal Artificial Neural Networks (SANNs)</i>	Rede neuronal proposta por Hamzaebi (2008) baseada nas ANNs, que identifica o número de neurónios de entrada e saída através da sazonalidade da série (Khandelwal et al., 2015)
<i>Recurrent Neural Networks (RNNs)</i>	O seu principal objetivo é utilizar, interpretar e aprender um conjunto de observações passadas para prever dados futuros, criando uma previsão de séries temporais. (Siami-Namini et al., 2018) Existem constrangimentos associados a este tipo de rede, tais como quanto mais camadas forem adicionadas à rede, os gradientes da função aproximam-se de zero, dificultando o seu treino. (Lee et al., 2019)
<i>Long Short Term Modeling (LSTM)</i>	Introduzida por Hochreiter e Schmidhuber (1997) que permite memorizar e processar grandes quantidades de dados. (Siami-Namini et al., 2018). Vem também resolver o constrangimento apresentado das RNN. (Lee et al., 2019)

Fonte: Próprio autor

2.3.3 Seleção da Abordagem

Atendendo aos objetivos do trabalho de investigação torna-se essencial selecionar a abordagem que mais se adequa ao mesmo.

Primeiramente, é importante compreender se a abordagem será estatística ou de aprendizagem automática. Dado que a análise é feita para um período temporal de longo prazo, enquadra-se melhor a última abordagem e, tratando-se de dados que não têm relações lineares as abordagens tradicionais não atuam da melhor forma. (Hans, J. H., 2018) Posto isto, e visto que se irá lidar com algum histórico de dados será seguida a abordagem de machine learning.

Tendo em conta as redes neuronais apresentadas no ponto acima (2.3.2), a selecionada foi a LSTM, uma vez que tem vindo a ganhar destaque nas previsões de séries temporais. Tal deve-se muito ao seu algoritmo de otimização iterativo cujo principal objetivo é ir ao encontro do melhor resultado. Este algoritmo gera uma série de resultados para que seja possível selecionar o melhor de todos, ou seja, o que tiver menor erro associado. (Siami-Namini et al., 2018)

2.3.4 Estudos desenvolvidos com recurso à abordagem LSTM

Um dos objetivos propostos para a realização da dissertação foi o desenvolvimento de um modelo de previsão temporal. Com a abordagem selecionada torna-se importante analisar estudos realizados onde neles, se tenha seguido esta abordagem de aprendizagem automática de forma a compreender se esta se trata de opção válida e com bons resultados de performance.

Não foi realizado até à data nenhum estudo semelhante ao proposto neste trabalho. Contudo, foram desenvolvidos alguns modelos com recurso ao LSTM em temáticas relacionadas com a sustentabilidade e o impacto que podem vir a ter na mesma.

O primeiro exemplo de aplicação do LSTM foi o desenvolvimento de um modelo na área da rede elétrica inteligente que consiste na gestão da geração, distribuição e consumo de eletricidade. A abordagem é utilizada para fazer uma análise preditiva ao preço e carregamento da eletricidade. Uma das conclusões a que se chegou foi que o preço da eletricidade é sazonal pelo que os dados foram divididos tendo em conta este ponto, melhorando a exatidão das previsões geradas pelo modelo. (Mujeeb et al., 2019)

O estudo seguinte procurou relacionar uma temática ambiental – emissões de dióxido de carbono – com uma temática económica – PIB per capita em cinco países africanos. Inicialmente estudou-se as implicações das emissões de CO₂ no PIB dos países ao longo dos últimos anos. O passo que se seguiu foi o desenvolvimento de um modelo preditivo com recurso à abordagem de aprendizagem automática, com o objetivo de prever a evolução das emissões de CO₂. O trabalho inclui ainda recomendações baseadas na relação entre as duas variáveis e nas projeções feitas pelo modelo. (Ameyaw and Yao, 2018)

Outro exemplo de aplicabilidade da abordagem foi na previsão de inundações no Vietname. Este fenómeno muitas vezes é a causa de perdas económicas e sociais para um país. Para o modelo foram tidos em conta os dados de descarga diária de água e precipitações entre os anos de 2000 e 2015. Ao todo, foram tidos em conta três cenários: previsão a um dia, dois dias e três dias. (Le et al., 2019)

Todos os exemplos de estudo apresentados em cima têm algo em comum: os resultados de exatidão e performance dos modelos desenvolvidos revelaram-se muito bons validando a escolha desta abordagem como viável para a previsão de séries

temporais.

3. Descrição do Trabalho Empírico

Este capítulo antecede a criação dos modelos pelo que será apresentada a linguagem de programação utilizada para tal bem como a justificação dos ODS selecionados, cujos indicadores serão alvo de tratamento para o desenvolvimento dos modelos.

3.1 Justificação da escolha dos Objetivos de Desenvolvimento Sustentável

Em julho de 2017, na Apresentação Nacional Voluntária no Fórum Político de Alto Nível das Nações Unidas, Portugal expôs as suas prioridades estratégicas no cumprimento das metas dos ODS até 2030.

À luz das suas necessidades e capacidades de implementação foram definidos pelo país como prioridade seis ODS, sendo que não é de competência única do Governo delinear e implementar medidas que assegurem o cumprimento da Agenda. É uma tarefa conjunta entre os setores público e privado havendo uma série de iniciativas adotadas por diferentes organizações nos objetivos definidos como mais relevantes para Portugal.

A educação, a igualdade de género e a redução de desigualdades, isto é, ODS 4, ODS 5 e ODS 10, são considerados importantes pois visam inverter atrasos históricos sociais procurando desenvolver uma sociedade mais qualificada, mais moderna e mais equitativa (República Portuguesa – Negócios Estrangeiros, 2017).

No Fórum Político foi justificada a aposta no ODS 9 dado que, com a modernização da indústria Portugal pretende desenvolver infraestruturas que minimizem o impacto ambiental para uma melhor mitigação das alterações climáticas. Posto isto, o ODS 13 respeitante à ação climática está também na lista de prioridades do país pois cada vez mais os compromissos assumidos devem ser assegurados de forma a reduzir impactos que prejudiquem o planeta.

Por fim, e tendo Portugal a costa mais larga de todos os países membro da União Europeia, deve assumir um papel relevante na gestão e sustentabilidade dos oceanos definindo assim, o ODS 14 como importante para a estratégia nacional.

Tendo em conta as prioridades nacionais estabelecidas, os objetivos apresentados

em cima foram os selecionados para o desenvolvimento do modelo de previsão proposto para este trabalho de investigação, para cada um dos indicadores que os endereçam.

3.2 Situação atual de Portugal no cumprimento da Agenda 2030

De acordo com o reporte de 2019 (SDSN & IEEP, 2019), no panorama europeu, a Suécia é o país mais bem cotado no que toca aos progressos feitos ao longo dos últimos cinco anos nos 17 objetivos.

Aquando a realização do reporte, Portugal ocupava a segunda metade das posições mais precisamente o 15º lugar. Olhando a que foram considerados 28 países membro (incluindo o Reino Unido) esta não é uma posição muito favorável.

De acordo com a informação disponibilizada no relatório é possível ter uma visão detalhada do progresso de cada país. Analisando o panorama nacional Portugal não tinha, à data de lançamento do reporte, nenhum objetivo alcançado. Quatro objetivos apresentam alguns desafios para que possam ser cumpridas na totalidade as metas estabelecidas, tratando-se do ODS 1, ODS 4, ODS 8 e ODS 16. Também quatro dos objetivos apresentam sérias dificuldades de cumprimento, sendo neste caso o ODS 9, o ODS 12, o ODS 14 e o ODS 15. Os restantes nove apresentam desafios significativos. De notar que dois dos objetivos definidos como prioritários para Portugal, ODS 9 e ODS 14, estão com dificuldades acrescidas, dois com desafios significativos, ODS 10 e ODS 13 e somente o ODS 4 está bem encaminhado tendo apenas alguns desafios a cumprir (SDSN & IEEP, 2019).

3.3 Seleção da linguagem de programação

Para a construção do modelo de previsão foi selecionada como linguagem de programação o *Python*. Esta linguagem de programação criada por *Guido Van Rossum* em 1989, teve como inspiração para o seu nome a série da *BBC* “*Monty Python’s Flying Circus*”. O principal objetivo do seu criador era facilitar a leitura de código e aumentar a produtividade dos utilizadores (‘History of Python’, 2019).

Esta é uma das linguagens mais utilizadas mundialmente ocupando o terceiro lugar no ranking do *TIOBE Index* de 2020 (Index | TIOBE – The Software Quality Company, 2020).

Uma das principais razões que levaram à escolha desta linguagem foi o facto de uma das suas áreas de especialidade ser a ciência dos dados. Outras características que lhe confere vantagens é a sua interface *user-friendly* uma vez que é de fácil compreensão e ainda a variedade de bibliotecas que disponibiliza facilitando a produtividade de quem utiliza esta linguagem poupando tempo de programação que seria manual.

3.4 Estrutura do Framework dos Objetivos de Desenvolvimento Sustentável

3.4.1 Indicadores da Organização das Nações Unidas (ONU)

A estrutura e organização do *framework* dos Objetivos de Desenvolvimento Sustentável foi desenvolvida pela *Inter-Agency and Expert Group on SDG indicators (IAEG – SDGs)*. Foi aceite em março de 2017 durante a realização da 48ª sessão da *United Nations Statistical Commission*.

Foram acordados os 17 objetivos que se dividem em targets, que por sua vez se dividem em *sub-targets* ou indicadores. Ao longo dos diferentes objetivos são contabilizados 169 *targets*, sendo que 32 deles se repetem entre os diferentes objetivos, perfazendo assim um total de 137 *targets* distintos. O mesmo acontece para os indicadores em que, únicos são contabilizados 231 havendo 12 que se multiplicam entre os targets. (Statistical Commission, 2018)

A *IAEG-SDGs* estipulou três grupos/ camadas onde os indicadores são classificados de acordo com a disponibilidade dos dados e o seu desenvolvimento. A forma como os indicadores são classificados depende de uma série de critérios apresentada de seguida:

- i. *Grupo 1*: o indicador está conceptualmente claro e os dados são disponibilizados regularmente por pelo menos 50% dos países e populações, cobrindo todas as regiões onde o indicador é estrategicamente importante (IAEG-SDGs, 2020);
- ii. *Grupo 2*: o indicador está conceptualmente claro, contudo os dados não são disponibilizados de forma regular pelos países (IAEG-SDGs, 2020);
- iii. *Grupo 3*: não estão disponíveis metodologias e *standards* internacionais ainda que estejam a ser, ou venham a ser, desenvolvidas (IAEG-SDGs, 2020).

Os indicadores são alvo de revisões e monitorizações constantes sendo que estas são feitas a um nível global, nacional e regional. A monitorização ao nível global é feita por uma plataforma gerida pela ONU, a *United Nations High Level Political Forum*.

De forma a assegurar que a Agenda 2030 é cumprida o compromisso dos países é fundamental pelo que devem ser estes a realizar as suas próprias revisões e avaliações de progressos a nível nacional e regional.

No início do presente ano a *United Nations Statistical Commission* conduzia o que viria a ser uma reformulação dos indicadores, resultando na aprovação de 36 grandes alterações - desde substituição, adição e eliminação de indicadores. À data da realização do trabalho em estudo é contabilizado um total de 231 indicadores, sendo que a próxima revisão está prevista para o ano de 2025.

Todos os anos é lançado um relatório que tem como objetivo fazer o ponto de situação do cumprimento da Agenda sendo feita uma análise aos progressos realizados a nível global bem como uma visão mais detalhada de cada país membro.

Os dados relativos a cada ODS estão disponíveis no *website* oficial da ONU. A informação pode ser consultada das seguintes formas:

- i. Por ODS (subdividindo-se em *targets* e indicadores);
- ii. Por área geográfica;
- iii. Por ano (informação disponível entre os anos 2000 e 2019)

3.4.2 Indicadores da União Europeia (UE)

Atendendo a todas as temáticas e de forma a conseguir monitorizar o progresso dos ODS no contexto da UE, o *Eurostat* - gabinete estatístico da União europeia, fundado em 1958, juntamente com as organizações dos Estados membro e outros serviços comissionários no *European Statistical System (ESS)*, desenvolveu uma *framework* de indicadores próprios. Estes estão alinhados com a lista global de indicadores das Nações Unidas contudo, não são totalmente idênticos. Isto permite que haja um maior foco na monitorização das políticas da UE e fenómenos particularmente relevantes no contexto europeu.

O *EU SDG Indicator* foi oficialmente aceite em maio de 2017, sendo que os indicadores foram selecionados de acordo com a relevância política no panorama da UE e disponibilidade e qualidade dos dados para cada país. (European Union, 2020).

65 dos indicadores da União Europeia estão alinhados com os indicadores das Nações Unidas e existe um total de 140 indicadores sendo que 36 são comuns a vários ODS.

Tal como acontece com os indicadores da ONU também estes são alvo de constantes revisões, não só ao nível de ajustes nos indicadores como a inclusão de novas

tecnologias, metodologias e fontes de dados. Por exemplo, o *Eurostat* encontra-se a trabalhar em conjunto com outros serviços da Comissão Europeia e a EEE para o uso de novas fontes de dados, como a integração de dados provenientes de observações terrestres.

3.4.3. Seleção do Framework

Para a realização da dissertação foram tidos em conta os indicadores desenvolvidos pela União Europeia, pelas seguintes razões:

Indicadores desenvolvidos à luz das necessidades e prioridades europeias, havendo uma maior incidência e atenção a um menor número de países (28 países *vs* 193 países);

Os indicadores disponibilizados pela ONU apresentam maiores *gaps* temporais e menos dados para Portugal, dificultando e colocando em causa os resultados de cada modelo a desenvolver.

Em baixo, é apresentado um glossário para cada ODS com a descrição do mesmo, dos indicadores, das unidades de medida estatísticas utilizadas para a apresentação dos valores ao longo dos últimos anos e, a última atualização de dados para cada indicador.

Tabela III
Glossário ODS 4

ODS	Descrição ODS	Indicador	Descrição Indicador	Descrição dos Dados	Unidade de Medida
4	Educação de Qualidade	4.1	Abandono precoce da educação	População entre os 18 e os 24 anos com até o ensino secundário que não frequentou qualquer estabelecimento de ensino até 4 semanas antes do inquérito	% da população entre 18-24 anos
		4.2	Abandono precoce da educação por cidadania	População entre os 18 e os 24 anos com até o ensino secundário, que se encontram em risco de pobreza, que não frequentou qualquer estabelecimento de ensino até 4 semanas antes do inquérito	% da população entre 18-24 anos
		4.3	Nível educacional superior	População entre os 30 e os 34 anos que completou com sucesso os seus estudos superiores (ex: universidades)	% da população entre os 30-34 anos
		4.4	Participação na educação infantil	Crianças entre os 4 anos e a idade para o começo do ensino primário que participaram na educação pré-primária	% da população entre os 4-6 anos
		4.5.1	Baixo aproveitamento escolar em literatura	Jovens com 15 anos que falharam o nível básico, na escala de PISA, na disciplina de literatura	% de jovens com 15 anos
		4.5.2	Baixo aproveitamento escolar em matemática	Jovens com 15 anos que falharam o nível básico, na escala de PISA, na disciplina de matemática	% de jovens com 15 anos
		4.5.3	Baixo aproveitamento escolar em ciências	Jovens com 15 anos que falharam o nível básico, na escala de PISA, na disciplina de ciências	% de jovens com 15 anos
		4.6	Taxa de empregabilidade de recentes licenciados	Taxa de empregabilidade na população entre os 20-34 anos (sendo que um dos critérios é terem pelo menos o ensino secundário concluído)	% da população entre os 20-34 anos
		4.7	Participação dos adultos na educação	População entre os 25 e 64 anos que afirmam ter recebido educação ou formação 4 semanas antes do inquérito ser realizado	% da população entre os 25-64 anos

Fonte: *Eurostat* (2020)

Os indicadores apresentados na tabela III pretendem garantir, em suma, que todos os jovens e crianças têm acesso a todo o tipo de ensino, tanto básico como secundário, e que as crianças iniciem desde cedo a sua educação frequentando a pré-escolaridade.

Pretende-se também que a população opte cada vez mais por prosseguir os seus estudos após o término do ensino obrigatório e ainda, que a taxa de empregabilidade da população recém-licenciada aumente significativamente.

Tabela IV
Glossário ODS 5

ODS	Descrição ODS	Indicador	Descrição Indicador	Descrição dos Dados	Unidade de Medida
5	Igualdade de Género	5.1	Violência física e sexual em mulheres	População feminina que experienciaram violência física/sexual pelos companheiros ou desconhecidos	% de população feminina por intervalo de idades
		5.2	Diferença salarial entre homens e mulheres	Diferença entre a média de horas laborais pagas aos homens e pagas às mulheres	% da média de horas pagas aos homens
		5.3	Gap de empregabilidade entre género	Diferença entre taxas de empregabilidade entre homens e mulheres entre os 20 e os 64 anos	%
		5.4	População inativa devido a responsabilidades de cuidadores	População que não se encontra empregada por: não estar à procura de emprego, por responsabilidades de cuidados familiares, incapacidades físicas e outras razões familiares	% da população inativa entre os 20-64 anos
		5.5.1	Proporção de lugares ocupados por mulheres no Parlamento	Proporção de mulheres no Parlamento	% de lugares
		5.5.2	Proporção de lugares ocupados por mulheres no Governo	Proporção de mulheres no Governo	% de lugares
		5.6.1	Proporção de cargos ocupados por mulheres como Membros do Conselho	População feminina que faz parte dos quadros de grandes empresas como Membros de Conselho	% de posições
		5.6.2	Proporção de cargos ocupados por mulheres como Executivas	População feminina que faz parte dos quadros de grandes empresas como Executivas	% de posições
		5.7	Abandono precoce da educação	População entre os 18 e os 24 anos com até o ensino secundário que não frequentou qualquer estabelecimento de ensino até 4 semanas antes do inquérito	% da população entre 18-24 anos
		5.8	Nível educacional superior	População entre os 30 e os 34 anos que completou com sucesso os seus estudos superiores (ex: universidades)	% da população entre os 30-34 anos
		5.9	Taxa de empregabilidade de recentes licenciados	Taxa de empregabilidade na população entre os 20-34 anos (sendo que um dos critérios é terem pelo menos o ensino secundário concluído)	% da população entre os 20-34 anos

Fonte: Eurostat (2020)

Os indicadores que constituem o objetivo apresentado na tabela IV visam terminar com todo o tipo de violência para com as mulheres, diminuir as disparidades no ramo profissional entre homens e mulheres desde minimização de diferenças salariais a oportunidades equitativas para ambos. Este ODS tem três indicadores em comum com o objetivo anterior, sendo que neste em questão eles irão subdividir-se em sexo enquanto no de cima irá ser analisado o agregado.

Tabela V
Glossário ODS 9

ODS	Descrição ODS	Indicador	Descrição Indicador	Descrição dos Dados	Unidade de Medida
9	Indústria, Inovação e Infraestruturas	9.1	Despesa nacional em R&D	Gastos com R&D em percentagem do PIB	% do PIB
		9.2	Recursos humanos em ciência e tecnologia	População entre os 25-64 anos que trabalha na área de ciências e tecnologias	% da população empregada entre os 25-64 anos
		9.3	R&D Personnel	Repartição pelos setores de Negócio, Governo, Educação, Privados sem fundos lucrativos	% da população empregada entre os 25-64 anos
		9.4	Pedidos de Patentes ao Instituto Europeu de Patentes	Número de pedidos de patentes ao European Patent Office, mesmo que não sejam aceites	Número por milhão de habitantes
		9.5	Transporte de passageiros através de autocaros e comboios	Performance dos transportes terrestres	% total de passageiros-km
		9.6	Participação de ferrovias e hidroviárias no transporte de carga	Participação das vias ferroviárias no transporte total de cargas	% frota ton-km
		9.7	Emissões médias de CO2 por km, de novos passageiros	Média de emissões de CO2 por km a cada novo passageiro	CO2-km

Fonte: Eurostat (2020)

O objetivo apresentado na tabela V, contempla indicadores que pretendem assegurar o aumento na aposta na investigação científica para contribuir para o desenvolvimento tecnológico. Defendem ainda o uso eficiente de recursos mais amigos do ambiente e ainda uma maior contribuição da indústria para o Produto Interno Bruto (PIB) e empregabilidade.

Tabela VI
Glossário ODS 10

ODS	Descrição ODS	Indicador	Descrição Indicador	Descrição dos Dados	Unidade de Medida
10	Redução de Desigualdades	10.1	PIB ajustado de poder de compra	Total de bens e serviços produzidos pela economia excluindo consumos internos	PPS, Index EU27_2020=100
		10.2	Rendimento bruto familiar per capita	Poder de compra das famílias e capacidade de investimento em bens e serviços que irão dispor no futuro	Index EU27_2020=100
		10.3	Mediana relativa do risco de pobreza	Diferença da mediana entre o total de rendimentos das famílias abaixo do risco de pobreza e em risco de pobreza	% de distância até à pobreza
		10.4	Distribuição de rendimento	Desigualdade existente entre os rendimentos da população	Rácio de quintis
		10.5	Pedidos de asilo	Número do primeiro pedido de asilo por cada milhão de habitantes	Número por milhão de habitantes
		10.6	Participação no rendimento de 40% da população mais pobre	Rendimentos de 40% da população mais pobre	% de rendimento
		10.7	Pessoas em risco de pobreza depois de pagamento de encargos	População com rendimento abaixo do limite da pobreza, que é fixado em 60% do rendimento disponível nacional	% da população
		10.8	Abandono precoce da educação	População entre os 18 e os 24 anos com até o ensino secundário que não frequentou qualquer estabelecimento de ensino até 4 semanas antes do inquérito	% da população entre 18-24 anos
		10.9	Jovens que não trabalham nem estudam	População entre os 15 e 29 anos que não trabalha nem estuda	% da população entre 15-29 anos
		10.10	Empregabilidade por cidadania	População entre os 20 e os 64 anos que está empregada	% da população entre 20-64 anos

Fonte: Eurostat (2020)

* caso o valor do país seja superior a 100 quer dizer que está acima da média da EU

Na tabela VI estão presentes os indicadores do 10º ODS que procuram garantir a inclusão social, económica e política para todas as populações, eliminando a discriminação de idade, sexo, raça, religião, etnia e outros. Todos estes aspetos pretendem refletir-se numa diminuição das desigualdades existentes entre os rendimentos da população, maior número de jovens que não abandona precocemente a sua educação bem como a diminuição do número de pessoas que se encontra abaixo do limite de pobreza nacional.

Tabela VII

Glossário ODS 13

ODS	Descrição ODS	Indicador	Descrição Indicador	Descrição dos Dados	Unidade de Medida
13	Ação Climática	13.1	Emissões Efeito de Estufa	Emissões totais nacionais	Index 1990=100 e toneladas/CO2 per capita
		13.2	Intensidade de emissões de efeito de estufa do consumo de energia	Rácio entre as emissões energéticas relativas ao efeito de estufa e o consumo energético nacional	Index 2000=100
		13.3	Perdas económicas relacionadas com o clima - Agregado EU	Perdas económicas devido a questões climáticas	EUR (milhão)
		13.4	Contribuição para o compromisso internacional de 100 biliões de dólares para o clima	Total despendido pelos países para contribuir para o clima do budget estabelecido	EUR (milhão)
		13.5	Participação das energias renováveis nos gastos totais de consumo energético	Peso das energias renováveis no consumo energético nacional	%
		13.6	Emissões médias de CO2 por km, de novos passageiros	Média de emissões de CO2 por km a cada novo passageiro	CO2-km
		13.7	Desvio médio de temperatura à superfície	Evolução das temperaturas à superfície	Graus Celsius
		13.8	População abrangida pela Covenant of Mayors for Climate & Energy	População abrangida	Milhões de habitantes
		13.9	Acidez média global da superfície do oceano	Acidez média do oceano	Ph

Fonte: Eurostat (2020)

* caso o valor do país seja superior a 100 quer dizer que está acima da média da EU

Sumariamente na tabela VII, está o objetivo que é constituído por indicadores que pretendem que até 2030 as emissões de gases de efeito de estufa sejam significativamente reduzidas, que a população adote cada vez mais opções sustentáveis, tocando ainda em temáticas relacionadas com questões atmosféricas.

Tabela VIII
Glossário ODS 14

ODS	Descrição ODS	Indicador	Descrição Indicador	Descrição dos Dados	Unidade de Medida
14	Proteção da Vida Marinha	14.1	Superfícies de locais marinhos designados sob NATURA 2000	Superfície de locais marinhos	km ²
		14.2	Tendência estimada do stock de peixes no Atlântico Nordeste		
		14.3	Stock de peixe avaliados excedem a taxa de mortalidade no Atlântico Nordeste		
		14.4.1	Locais de banho com excelente qualidade de água - Águas Costeiras	Indicadores de acordo com os parâmetros microbiológicos	Número ou % de locais
		14.4.2	Locais de banho com excelente qualidade de água - Águas Interiores	Indicadores de acordo com os parâmetros microbiológicos	Número ou % de locais
		14.5	Acidez média global da superfície do oceano	Acidez média do oceano	Ph

Fonte: Eurostat (2020)

Os indicadores acima visam uma maior proteção dos ecossistemas marinhos minimizando os impactos da acidificação dos oceanos, reporte da prática de pesca ilegal havendo uma melhor regulação bem como a proibição de determinados subsídios de pesca que contribuam para a prática excessiva da mesma.

3.5 Exploração do Dataset

Nesta fase já é conhecida a população-alvo, sendo os indicadores respeitantes aos seis ODS identificados como prioritários para Portugal desenvolvidos pela União Europeia. A abordagem que irá ser seguida para o desenvolvimento de cada modelo e a linguagem de programação utilizada para tal estão também definidas.

Para assegurar uma boa previsão de valores, os dados serão alvo de uma exploração e tratamento iniciais.

O principal objetivo é criar e treinar um modelo para cada indicador que indique os respetivos valores até 2030. As variáveis em análise são os valores anuais (percentuais ou numéricos) por indicador para Portugal registados até ao momento da escrita da dissertação. Ao todo foram desenvolvidos 52 modelos, todos com a mesma estrutura.

Antes de desenvolver cada modelo é necessário fazer um tratamento de dados que passa pela importação dos ficheiros em formato CSV, eliminação de valores nulos e ainda conversão de variáveis.

Entrando em maior detalhe nos passos seguidos mais relevantes, em primeiro lugar foi feita a importação das bibliotecas necessárias ao desenvolvimento de cada modelo.

Importação das bibliotecas

```

from keras.preprocessing.sequence import TimeseriesGenerator
from tensorflow.keras.models import Sequential
from keras.layers import Dense
from keras.layers import LSTM
from keras.layers import Dropout
import numpy as np
import pandas as pd
import matplotlib.pyplot as plt
from sklearn.preprocessing import MinMaxScaler
from sklearn.metrics import mean_squared_error
from math import sqrt

```

Em baixo, encontram-se duas tabelas que caracterizam as bibliotecas e as respetivas classes mais relevantes utilizadas para os modelos.

Tabela IX

Descrição das bibliotecas utilizadas, mais relevantes, para desenvolvimento do modelo

Biblioteca	Descrição
<i>Keras</i>	Interface de programação em <i>Python</i> que pretende ser altamente produtiva e eficaz a solucionar problemas de <i>deep learning</i>
<i>Sklearn.preprocessing</i>	Fornece inúmeras funções e classes que permitem alterar certas características nos vetores
<i>Sklearn.metrics</i>	Avaliação de performance de modelos
<i>Pandas</i>	Fornece ferramentas de manipulação de dados e de análise de dados

Fonte: Próprio Autor

Tabela X

Descrição das classes utilizadas, mais relevantes, para desenvolvimento do modelo

Biblioteca	Classe	Descrição
<i>Keras</i>	<i>Long Short Term Modelling</i>	Muito utilizada para previsão de séries temporais graças à sua capacidade de armazenamento de grande quantidade de dados históricos
	<i>Sequential</i>	Classe que agrupa um conjunto linear de <i>layers</i>
	<i>Droupout</i>	Técnica em que um conjunto selecionado aleatoriamente de neurónios é eliminado durante o treino do modelo (Srivastava, et al 2014)
	<i>Dense</i>	Classe onde é determinado o número de matrizes do output
	<i>Fit_Generator</i>	Classe de treino do modelo muito utilizada para tratar maiores quantidades de dados
	<i>TimeSeriesGenerator</i>	Classe que cria um dataset de séries temporais na forma de matriz
<i>Sklearn.preprocessing</i>	<i>MinMaxScaler</i>	Classe que transforma um conjunto de dados em escala
<i>Sklearn.metrics</i>	<i>Mean_Squared_Error</i>	Classe que retorna a diferença média quadrática entre os valores estimados e o que é estimado
<i>Pandas.tseries.offsets</i>	<i>DateOffset</i>	Classe que acrescenta uma data futura a partir de um conjunto de datas

Fonte: Próprio Autor

De seguida é importado o ficheiro CSV que irá ser utilizado (ver Figura 1 em anexo).

```
# Importação ficheiro CSV
t4_1=pd.read_csv("SDG4-T1.csv")
```

É possível nesta fase realizar-se uma exploração dos dados para os preparar para o modelo pois há requisitos que têm de ser garantidos. Requisitos esses, que passam

```
# Preparação dos dados
t4_1.dropna(inplace=True)
t4_1['Ano']=pd.to_datetime(t4_1['Ano'],infer_datetime_format=True)
indexedt4_1=t4_1.set_index(['Ano'])
```

pela ordenação das datas pela ordem crescente, eliminação de valores nulos e, conversão das datas para o formato correto.

Garantidos os requisitos apresentados em cima, a amostra está pronta para ser dividida em treino e teste. A metodologia seguida para todos os modelos desenvolvidos foi a de 60% da amostra foi utilizada para treino e os restantes 40% para teste.

```
# Divisão da amostra
train, test=indexedt4_1[:10], indexedt4_1[10:]
```

O último passo é a transformação da amostra em escala pois é um requisito necessário do LSTM. Este passo tem também o nome de normalização da amostra.

```
# Conversão da amostra para escala
scaler=MinMaxScaler()
scaler.fit(train)
train=scaler.transform(train)
test=scaler.transform(test)
```

3.6 Desenvolvimento do Modelo

Após o tratamento inicial dos dados que culminou com a divisão da amostra em treino e teste, é possível começar a desenvolver o modelo de previsão, o seu respetivo treino no *dataset* e por fim, a aplicação no *dataset* de teste.

Trabalhando primeiramente com o *dataset* de treino este é transformado num *supervised learning problem*, ou seja é convertido numa matriz. Para tal, recorreu-se à função *TimeSeriesGenerator*, onde devem ser especificados o *Length* que é o número de observações/entradas do *dataset* de treino a serem considerados para a construção do modelo e o *Batch_size* que é o número de amostras a retornar em cada iteração.

```
# Transformação do dataset de treino em matriz

n_input=9
n_features=1
generator=TimeseriesGenerator(train,train,length=n_input,
batch_size=1)
```

Findo o passo anterior o modelo pode ser definido.

```
# Definição do Modelo

model=Sequential()
model.add(LSTM(200,activation='relu',input_shape=(n_input,
n_features)))
model.add(Dropout(0.15))
model.add(Dense(1))
model.compile(optimizer='adam', loss='mse')
```

O modelo está criado e pronto a ser treinado através da função *Fit_Generator*. Nesta função é necessário definir o número de *epochs*, uma vez que esta está programada para gerar resultados em *loop* infinitamente. A *epoch* define o número de vezes que o *dataset* irá ser treinado no modelo.

```
# Treino do modelo

model.fit_generator(generator, epochs=180)
```

Após o treino do modelo este está apto a ser aplicado no *dataset* de teste sendo que para tal são repetidos os primeiro e terceiro passos, culminando com as características pretendidas para o modelo devidamente definidas.

```
# Definição do modelo no dataset de teste

n_input=14
n_features=1
generator=TimeseriesGenerator(train4_1, train4_1, length=n_input,
batch_size=1)
model.fit_generator(generator, epochs=180)
```

Para a realização de previsões temporais os valores que são previstos pelo modelo vão sendo agrupados realizando-se um *loop*. O número de vezes que este é realizado depende de amostra para amostra, uma vez que está dependente do número de anos que faltam atingir até 2030. A título de exemplo, se para um indicador houver histórico até 2019 o *loop* terá de ser realizado no mínimo onze vezes.

```
# Realização do loop

from pandas.tseries.offsets import DateOffset
add_dates=[indexedt4_1.index[-1]+ DateOffset(years=x) for x in range
(0,11)]
```

Até este ponto, inclusive, a amostra ainda está sob a forma de escala. Segue-se a criação de um *dataframe* com os valores previstos.

```
# Criação do dataframe

future_dates=pd.DataFrame(index=add_dates[1:],
columns=indexedt4_1.columns)
```

Com os valores previstos estes serão convertidos para o formato numérico.

```
# Conversão do dataframe criado para valores numéricos

df_predict4_1=pd.DataFrame(scaler.inverse_transform(pred_list4_1),
index=future_dates[-n_input:].index, columns=['Predictions'])
df_proj4_1=pd.concat([indexedt4_1,df_predict4_1],axis=1)
```

Por fim, e de forma a ter uma visualização da evolução do indicador ao longo dos anos foi criado um gráfico (ver Figura 2, em anexo) no fim de cada modelo que espelha a evolução do indicador até ao momento atual e até ao ano de 2030.

```
# Criação de um gráfico

plt.figure(figsize=(10,4)) plt.plot(df_proj4_1.index,
df_proj4_1['Percentagem']) plt.plot(df_proj4_1.index,
df_proj4_1['Predictions'], color='r') plt.legend(loc='best',
fontsize='large') plt.xticks(fontsize=12) plt.yticks(fontsize=12)
plt.show()
```

3.7 Avaliação do Desempenho

Com a previsão dos valores dos indicadores para 2030 é importante avaliar a *performance* de cada um dos modelos criados. Dentro da área da aprendizagem automática podem ser aplicadas várias métricas para a avaliação de modelos. Dado que foram previstos valores futuros está-se perante modelos de regressão destacando-se três métricas: o *Mean Absolute Error* (MAE), o *Mean Squared Error* (MSE) e o *Mean Absolute Percentage Error* (MAPE).

A primeira métrica, MAE, mede a diferença entre duas variáveis contínuas, traduzindo-se na média dos erros de um conjunto de previsões.

A segunda métrica, MSE, representa a diferença entre as observações usadas para o desenvolvimento do modelo e as observações dos valores previstos pelo modelo. É das métricas mais consensuais pois é utilizada para avaliar a forma como o modelo faz *fit* com os dados. Dentro desta métrica destaca-se uma outra que é o *Root Mean Squared Error* - RMSE - sendo a raiz quadrada do MSE. Para efeito de interpretação de valores quanto mais baixo e próximo de zero forem, melhor.

A última métrica, MAPE, mede o erro da previsão pelo que, quanto mais baixo for o seu valor maior a exatidão do modelo. Os seus resultados vêm na forma de percentagem sendo que o seu método de interpretação é o seguinte:

MAPE \leq 10% - Exatidão forte 10%

$<$ MAPE \leq 20% - Boa Exatidão

20% $<$ MAPE \leq 50% - Exatidão Moderada

MAPE $>$ 50% - Fraca Exatidão

Para efeitos do estudo as métricas selecionadas para avaliação de cada um dos modelos foram o MSE, RMSE e MAPE cujos resultados se encontram na tabela em baixo.

Tabela XI
Resultados à análise de desempenho de cada modelo

ODS	Descrição ODS	Indicador	Descrição Indicador	MSE	RMSE	MAPE
4	Educação de Qualidade	4.1	Abandono precoce da educação	10,7	3,3	18,2
		4.2	Abandono precoce da educação por cidadania	12,8	3,6	21,1
		4.3	Nível educacional superior	11,4	3,4	44,7
		4.4	Participação na educação infantil	5,5	2,3	4,5
		4.5.1	Baixo aproveitamento escolar em literatura	2,6	1,6	10,7
		4.5.2	Baixo aproveitamento escolar em matemática	1,1	1,0	3,7
		4.5.3	Baixo aproveitamento escolar em ciências	1,1	1,0	6,7
		4.6	Taxa de empregabilidade de recentes licenciados	7,9	2,8	6,5
		4.7	Participação dos adultos na educação	3,5	1,9	14,7
5	Igualdade de Género	5.1	Violência física e sexual em mulheres			
		5.2	Diferença salarial entre homens e mulheres	6,7	2,6	27,4
		5.3	Gap de empregabilidade entre género	1,4	1,2	11,2
		5.4	População inativa devido a responsabilidades de cuidadores	5,4	2,3	18,7
		5.5.1	Proporção de lugares ocupados por mulheres no Parlamento	18,8	4,3	39,4
		5.5.2	Proporção de lugares ocupados por mulheres no Governo	18,4	4,3	38,7
		5.6.1	Proporção de cargos ocupados por mulheres como Membros do Conselho	15,5	3,9	38,9
		5.6.2	Proporção de cargos ocupados por mulheres como Executivas	29,4	5,4	48,9
		5.7.1	Abandono precoce da educação sexo feminino	8,4	2,9	11,8
		5.7.2	Abandono precoce da educação sexo masculino	9,2	3,0	13,4
		5.8.1	Nível educacional superior sexo feminino	13,3	3,6	20,5
		5.8.2	Nível educacional superior sexo masculino	6,2	2,5	16,2
		5.9.1	Taxa de empregabilidade de recentes licenciados sexo feminino	6,3	2,5	7,5
		5.9.2	Taxa de empregabilidade de recentes licenciados sexo masculino	6,7	2,6	6,9
		9	Indústria, Inovação e Infraestruturas	9.1	Despesa nacional em R&D	0,23
9.2	Recursos humanos em ciência e tecnologia			19,9	4,5	34,3
9.3	R&D Personnel			2	1,4	10,9
9.4	Pedidos de Patentes ao Instituto Europeu de Patentes			15	3,9	22,9
9.5	Transporte de passageiros através de autocarros e comboios			1,25	1,1	8,8
9.6	Participação de ferrovias e hidrovias no transporte de carga			5,5	2,3	9,2
9.7	Emissões médias de CO2 por km, de novos passageiros			17,4	4,2	12,7
10	Redução de Desigualdades	10.1	PIB ajustado de poder de compra	27,6	5,3	46,7
		10.2	Rendimento bruto familiar per capita	18,7	4,3	25,6
		10.3	Mediana relativa do risco de pobreza	3,1	1,8	7,6
		10.4	Distribuição de rendimento	0,92	1,0	4,1
		10.5	Pedidos de asilo	17,2	4,1	32,1
		10.6	Participação no rendimento de 40% da população mais pobre	17,6	4,2	33,4
		10.7	Pessoas em risco de pobreza depois de pagamento de encargos	1,7	1,3	8,2
		10.8	Abandono precoce da educação	15,7	4,0	23,2
		10.9	Jovens que não trabalham nem estudam	4,8	2,2	8,9
		10.10	Empregabilidade por cidadania	3,6	1,9	10,9
13	Ação Climática	13.1	Emissões Efeito de Estufa	5,8	2,4	11,7
		13.2	Intensidade de emissões de efeito de estufa do consumo de energia	16,1	4,0	20,4
		13.3	Perdas económicas relacionadas com o clima - Agregado EU	19	4,4	28,3
		13.4	Contribuição para o compromisso internacional de 100 biliões de dólares para o clima	31,5	5,6	49,3
		13.5	Participação das energias renováveis nos gastos totais de consumo energético	11,4	3,4	17,4
		13.6	Emissões médias de CO2 por km, de novos passageiros	23,4	4,8	12,7
		13.7	Desvio médio de temperatura à superfície	0,2	0,4	9,5
		13.8	População abrangida pela Covenant of Mayors for Climate & Energy	18,6	4,3	36,3
		13.9	Acidez média global da superfície do oceano	0,02	0,1	0,2
14	Proteção da Vida Marinha	14.1	Superfícies de locais marinhos designados sob NATURA 2000	20,4	4,5	38,2
		14.2	Tendência estimada do stock de peixes no Atlântico Nordeste			
		14.3	Stock de peixe avaliados excedem a taxa de mortalidade no Atlântico Nordeste			
		14.4.1	Locais de banho com excelente qualidade de água - Águas Costeiras	6,1	2,5	7,8
		14.4.2	Locais de banho com excelente qualidade de água - Águas Interiores	6,3	2,5	7,6
14.5	Acidez média global da superfície do oceano	0,02	0,1	0,2		

Fonte: Próprio Autor

Analisando a tabela é possível comprovar que a exatidão é forte em 35% dos modelos criados, boa em 30% e moderada em 35%. Nenhum dos modelos apresenta uma exatidão acima dos 51% o que é bastante positivo.

Uma possível justificação para alguns dos valores acima dos 40%, tornando a exatidão moderada, pode dever-se ao facto de haver pouco histórico e o tipo de abordagem seguida funcionar melhor com um maior volume de dados.

4 Resultados

Os modelos desenvolvidos foram fundamentais para ser atingido um dos principais objetivos: ter a previsão dos valores por indicador até 2030.

É importante analisar os resultados para conseguir proceder a uma conclusão mais sustentada sobre a evolução que Portugal tem feito, e irá fazer, nos próximos dez anos.

De seguida irão ser apresentadas tabelas resumo de cada ODS que contempla o valor previsto para cada indicador em 2030 e o valor da meta a atingir pelos mesmos. Os valores a atingir foram definidos pelas Nações Unidas e União Europeia sendo que para alguns indicadores os valores estarão em branco pois não foi encontrada nenhuma informação credível que permitisse preencher os mesmos.

4.1 ODS 4 - Educação de Qualidade

Tabela XII
Resultados dos indicadores do ODS 4

ODS	Descrição ODS	Indicador	Descrição Indicador	Unidade	Previsão	Meta
4	Educação de Qualidade	4.1	Abandono precoce da educação	Percentagem	8,5	0
		4.2	Abandono precoce da educação por cidadania	Percentagem	7,6	0
		4.3	Nível educacional superior	Percentagem	43,0	100
		4.4	Participação na educação infantil	Percentagem	99,4	100
		4.5.1	Baixo aproveitamento escolar em literatura	Percentagem	19,4	0
		4.5.2	Baixo aproveitamento escolar em matemática	Percentagem	23,1	0
		4.5.3	Baixo aproveitamento escolar em ciências	Percentagem	18,2	0
		4.6	Taxa de empregabilidade de recentes licenciados	Percentagem	70,8	100
		4.7	Participação dos adultos na educação	Percentagem	10,5	100

Fonte: Próprio Autor

Legenda:

Meta – objetivo alcançado ou menos de 5% para o atingir

Meta – menos de 50% para atingir o objetivo

Meta – mais de 50% para atingir objetivo

No geral os valores são bastante positivos e Portugal estará bem encaminhado no que diz respeito à educação. Quase 100% das crianças irão ter acesso à educação pré-primária (indicador 4.4) representando um aumento de quase 30% face ao ano de 2000, que é o primeiro ano com registo de valores para o indicador em questão.

Um indicador que, apesar de não ser o pior em termos de valores, é merecedor de alerta é a percentagem de jovens, entre os 30 e os 34 anos, com um nível educacional superior (indicador 4.3) concluído ser abaixo dos 50%. Atendendo a este valor as razões podem ser diversas, desde dificuldades financeiras para garantir a manutenção nas

instituições de ensino ou dificuldades financeiras em arranjar um alojamento acessível, sem descurar as necessidades básicas de alimentação e transporte, caso o estudante pretenda estudar fora da sua cidade natal, ou até mesmo por falta de qualificações. Contudo, sendo a imagem futura apresentada de dez anos será legítimo afirmar que o país poderá encontrar formas de contornar estes valores aumentando-os significativamente.

Outro indicador que importa ressaltar é a taxa de empregabilidade dos recém-licenciados (indicador 4.6), em 2030 prevê-se uma diminuição de cerca de 12% face a 2018.

O indicador mencionado anteriormente repete-se no ODS 5, tal como os indicadores 4.1 - Abandono precoce da educação e 4.3 – Nível educacional superior, sendo que no ODS mencionado irá ser feita uma análise repartida por sexo uma vez que assim se justifica dado que contempla indicadores relacionados com a igualdade de género. De modo que no ODS em análise neste ponto é apresentado o resultado para o agregado de ambos os sexos.

Em anexo, na tabela XVIII, são apresentados os valores tidos em conta para o desenvolvimento dos modelos para cada indicador.

4.2 ODS 5 - Igualdade de Género

Tabela XIII
Resultados dos indicadores do ODS 5

ODS	Descrição ODS	Indicador	Descrição Indicador	Unidade	Previsão	Meta
5	Igualdade de Género	5.1	Violência física e sexual em mulheres			
		5.2	Diferença salarial entre homens e mulheres	Percentagem	21,6	0
		5.3	Gap de empregabilidade entre género	Percentagem	7,1	0
		5.4	População inativa devido a responsabilidades de cuidadores	Percentagem	14,8	0
		5.5.1	Proporção de lugares ocupados por mulheres no Parlamento	Percentagem	61,1	50
		5.5.2	Proporção de lugares ocupados por mulheres no Governo	Percentagem	52,8	50
		5.6.1	Proporção de cargos ocupados por mulheres como Membros do Conselho	Percentagem	49,9	50
		5.6.2	Proporção de cargos ocupados por mulheres como Executivas	Percentagem	12,0	50
		5.7.1	Abandono precoce da educação sexo feminino	Percentagem	5,1	0
		5.7.2	Abandono precoce da educação sexo masculino	Percentagem	14,6	0
		5.8.1	Nível educacional superior sexo feminino	Percentagem	48,1	100
		5.8.2	Nível educacional superior sexo masculino	Percentagem	29,9	100
		5.9.1	Taxa de empregabilidade de recentes licenciados sexo feminino	Percentagem	73,7	100
		5.9.2	Taxa de empregabilidade de recentes licenciados sexo masculino	Percentagem	81,2	100

Fonte: Próprio Autor

Legenda:

Meta – objetivo alcançado ou menos de 5% para o atingir

Meta – menos de 50% para atingir o objetivo

Meta – mais de 50% para atingir objetivo

Em relação a este objetivo importa salientar que não foi feita qualquer previsão para o primeiro indicador - Violência física e sexual em mulheres - uma vez que os dados disponíveis são referentes a um único ano (2012) e estão agrupados por faixas etárias pelo que não foram reunidos os requisitos necessários para o desenvolvimento de um modelo.

O indicador que terá uma maior ascensão, atingindo os 49,9% é o 5.6.1 – Proporção de cargos ocupados por mulheres como Membros do Conselho- estando a menos de um ponto percentual de atingir a meta estabelecida.

Como mencionado no ponto anterior, 5.1, voltam a ser alvo de análise os indicadores: Abandono precoce da educação (5.7.1 e 5.7.2), Nível educacional superior (5.8.1 e 5.8.2) e Taxa de empregabilidade de recentes licenciados (5.9.1 e 5.9.2). Relativamente ao primeiro, há uma diferença percentual de quase 10% entre o sexo feminino e o masculino. Olhando aos jovens com ensino superior concluído volta a haver um *gap* entre ambos, visto que está previsto que quase 50% da população alvo de estudo feminino venha a ter um curso superior enquanto a população masculina difere em quase 20%. Seria de esperar que face a estes números e diferenças significativas, a taxa de empregabilidade para as mulheres recém-licenciadas fosse superior à dos homens, mas tal não acontece.

Ainda que quase todos os indicadores estejam encaminhados de forma positiva, estando em 2030 muito próximos de atingir as metas, a diferença de géneros verificada nos dias de hoje, aparentemente irá manter-se até aos próximos 10 anos.

Em anexo, na tabela XIX, estarão apresentados os valores tidos em conta para o desenvolvimento dos modelos para cada indicador.

4.3 ODS 9 - Indústria, Inovação e Infraestruturas

Tabela XIV
Resultados dos indicadores do ODS 9

ODS	Descrição ODS	Indicador	Descrição Indicador	Unidade	Previsão	Meta
9	Indústria, Inovação e Infraestruturas	9.1	Despesa nacional em R&D	Percentagem	1,4	3,28
		9.2	Recursos humanos em ciência e tecnologia	Percentagem	45,9	N.D
		9.3	Pessoas em R&D	Percentagem	2,8	N.D
		9.4	Pedidos de Patentes ao Instituto Europeu de Patentes	Por milhão de habitantes	162	N.D
		9.5	Transporte de passageiros através de autocarros e comboios	Percentagem km/passageiros	11,7	N.D
		9.6	Participação de ferrovias e hidrovias no transporte de carga	Percentagem da frota terrestre	18,2	N.D
		9.7	Emissões médias de CO2 por km, de novos passageiros	Percentagem de CO2 por km	121,1	N.D

Fonte: Próprio Autor

Legenda:

Meta – mais de 50% para atingir objetivo

N.D – meta desconhecida

Este ODS engloba indicadores muito variados. Por exemplo, o 9.4 - Pedidos de Patentes ao Instituto Europeu de Patentes - foi sem dúvida o que mais evoluiu positivamente. Este poderá ser um sinal de que a aposta no empreendedorismo e nos novos negócios irá continuar a ser crescente, bem como os apoios que o Estado dá aos mesmos potenciando esta evolução.

Havendo cada vez mais a preocupação com a sustentabilidade, as marcas automóveis começam a ter na sua gama opções elétricas. Contudo, o indicador 9.7 - Emissões médias de CO2 por km, de novos passageiros - poderá indicar que a adesão será lenta e/ou mais fraca, uma vez que as emissões médias de dióxido de carbono, por novo passageiro, tendem a aumentar até 2030, quando o ideal seria o oposto. Hoje em dia o Estado apresenta benefícios fiscais para quem opte pela mobilidade elétrica, mas estes poderão não ser suficientemente atrativos. Outra possível alternativa é que, no presente ano ainda é algo escasso são os postos de carregamento disponíveis nas cidades pelo que, alargar o seu número poderá ser uma das soluções.

Em anexo, na tabela XX, são apresentados os valores tidos em conta para o desenvolvimento dos modelos para cada indicador.

4.4 ODS 10 - Redução das Desigualdades

Tabela XV
Resultados dos indicadores do ODS 10

ODS	Descrição ODS	Indicador	Descrição Indicador	Unidade	Previsão	Meta
10	Redução de Desigualdades	10.1	PIB ajustado de poder de compra	Numérico	35 840	N.D
		10.2	Rendimento bruto familiar per capita	Numérico	24 265	N.D
		10.3	Mediana relativa do risco de pobreza	Percentagem	24,1	N.D
		10.4	Distribuição de rendimento	Percentagem	5,2	N.D
		10.5	Pedidos de asilo	Numérico por milhão de habitantes	653,4	0
		10.6	Participação no rendimento de 40% da população mais pobre	Percentagem	19,5	1,09
		10.7	Pessoas em risco de pobreza depois de pagamento de encargos	Percentagem	20,5	0
		10.8	Abandono precoce da educação	Percentagem	8,5	0
		10.9	Jovens que não trabalham nem estudam	Percentagem	8,9	0
		10.10	Empregabilidade por cidadania	Percentagem	68,7	100

Fonte: Próprio Autor

Legenda:

Meta – menos de 50% para atingir o objetivo

Meta – mais de 50% para atingir objetivo

N.D – meta desconhecida

No geral este ODS apresenta valores de indicadores com apontamentos bastante positivos. A título de exemplo é bastante positivo observar que o rendimento bruto familiar (10.2) tende a ser crescente, potenciando o poder de compra das famílias, o que poderá indicar que os salários irão sofrer acréscimos durante os próximos anos ou mais pessoas no agregado familiar estarão empregadas.

Contudo esta última justificação pode ser contrariada se for analisado o indicador 10.10 - Empregabilidade por cidadania, cuja tendência é diminuir. Olhando a este último, a classe em estudo encontra-se entre os 20 e os 64 anos pelo que este valor poderá indicar que a população jovem pode vir a emigrar cada vez mais nos próximos dez anos e/ou a população mais adulta poderá estar a optar por se aposentar mais cedo.

O valor mais preocupante diz respeito aos pedidos de asilo - indicador 10.5 - que têm aumentado consideravelmente ao longo dos anos, e em 2030 estão previstos 650 pedidos por cada milhão de habitantes. Este pode ser um sinal de que se está longe enquanto país de proporcionar oportunidades e condições equitativas e justas para toda a população e é sem dúvida, um indicador que deve ser analisado com mais detalhe pelas entidades competentes.

Em anexo, na tabela XXI, estarão apresentados os valores tidos em conta para o desenvolvimento dos modelos para cada indicador.

4.5 ODS 13 – Ação Climática

Tabela XVI
Resultados dos indicadores do ODS 13

ODS	Descrição ODS	Indicador	Descrição Indicador	Unidade	Previsão	Meta
13	Ação Climática	13.1	Emissões Efeito de Estufa	Porcentagem	3,5	0
		13.2	Intensidade de emissões de efeito de estufa do consumo de energia	Porcentagem	81,3	N.D
		13.3	Perdas económicas relacionadas com o clima - Agregado EU	Numérico (milhão de EUR)	10 867	N.D
		13.4	Contribuição para o compromisso internacional de 100 biliões de dólares para o clima	Numérico (milhão de EUR)	2,2	N.D
		13.5	Participação das energias renováveis nos gastos totais de consumo energético	Porcentagem	45,8	N.D
		13.6	Emissões médias de CO2 por km, de novos passageiros	Porcentagem de CO2 por km	121,1	N.D
		13.7	Evolução das temperaturas à superfície	Graus Celsius	1,1	N.D
		13.8	População abrangida pela <i>Covenant of Mayors for Climate & Energy</i>	Numérico por milhão de habitantes	2 579	N.D
		13.9	Acidez média global da superfície do oceano	Média do pH	8,1	8-8,5

Fonte: Próprio Autor

Legenda:

Meta – objetivo alcançado ou menos de 5% para o atingir

Meta – menos de 50% para atingir o objetivo

N.D – meta desconhecida

A temática deste ODS tem estado no centro das preocupações mundiais ao longo dos últimos anos.

Um indicador que apresenta uma tendência positiva são os gastos da União Europeia em temáticas de clima (indicador 13.3), que irão diminuir nos próximos anos o que indica que os países estarão a tomar medidas preventivas e eficazes que não prejudicam o clima e a sua sustentabilidade futura.

Outro bom indicador é o que diz respeito às energias renováveis e consumo energético (indicador 13.5) que em 2030 estará próximo dos 50%, o que revela uma maior aposta em alternativas mais amigas do ambiente.

Em anexo, na tabela XXII, são apresentados os valores tidos em conta para o desenvolvimento dos modelos para cada indicador.

4.6 ODS 14 - Proteção da Vida Marinha

Tabela XVII
Resultados dos indicadores do ODS 14

ODS	Descrição ODS	Indicador	Descrição Indicador	Unidade	Previsão	Meta
14	Proteção da Vida Marinha	14.1	Superfícies de locais marinhos designados sob NATURA 2000	km2	54 738	N.D
		14.2	Tendência estimada do stock de peixes no Atlântico Nordeste			
		14.3	Stock de peixe avaliados excedem taxa de mortalidade no Atlântico Nordeste			
		14.4.1	Locais de banho com excelente qualidade de água - Águas Costeiras		506,5	N.D
		14.4.2	Locais de banho com excelente qualidade de água - Águas Interiores		158,1	N.D
		14.5	Acidez média global da superfície do oceano	Média do pH	8,1	8-8,5

Fonte: Próprio Autor

Legenda:

Meta – objetivo alcançado ou menos de 5% para o atingir

N.D – meta desconhecida

Há dois indicadores presentes neste ODS que não foram tidos em conta para o trabalho uma vez que não impactam Portugal, nem Portugal impacta ou compromete o seu cumprimento: indicadores 14.2 e 14.3.

No geral este ODS contempla indicadores com previsões bastante positivas, desde logo analisando os locais destinados a banhos com o certificado de qualidade de água excelente para tal vão aumentar até 2030.

Em anexo, na tabela XXIII, são apresentados os valores tidos em conta para o desenvolvimento dos modelos para cada indicador.

5 Conclusões

Entrando na fase final do trabalho de investigação e tendo já analisado os resultados, de seguida são lembrados os objetivos que foram propostos e definidos no primeiro capítulo:

- i. Identificação e comparação de diferentes abordagens de previsão de séries temporais;
- ii. Identificação dos ODS prioritários para Portugal;
- iii. Proposta de modelo de previsão para os ODS;
- iv. Avaliação dos resultados dos modelos de previsão desenvolvidos.

O grande objetivo do estudo era perceber em que ponto da Agenda 2030 Portugal estará tendo para tal desenvolvido um modelo de previsão temporal para cada um dos 52 indicadores em estudo. Para tal, foi necessário estudar qual a abordagem que ia ser seguida para o seu desenvolvimento tendo em conta o tipo de dados que iriam ser analisados e o histórico dos mesmos. A Revisão de Literatura revelou-se fundamental no estudo das diferentes abordagens existentes para a previsão de séries temporais. Foi feita uma análise com base em estudos científicos para que fosse selecionada não apenas a melhor abordagem como também a que mais se adequava ao trabalho proposto. A abordagem considerada foi o *Long Short Term Modeling*, um tipo de rede neuronal que se revelou complexa mas com bons resultados, compensando as adversidades. Tendo a abordagem selecionada foi necessário definir que linguagem de programação iria ser utilizada para desenvolver os modelos. Esta foi o *Python* que revelou ter sido uma boa escolha graças à sua fácil escrita e interpretação de código bem como a disponibilização das bibliotecas e funções necessárias à construção de cada modelo. Após a identificação tanto da técnica de aprendizagem automática e linguagem de programação foi possível desenvolver cada um dos modelos.

Os dados tidos em conta para os modelos foram à partida os 17 objetivos estipulados pela ONU contudo, dado o elevado volume de indicadores respeitantes aos objetivos, foi definido que para a realização do estudo iriam ser tidos em conta apenas alguns. Dado que o estudo se centrou em compreender o progresso realizado por Portugal, foi feita uma pesquisa pelos ODS mais prioritários para o país tendo chegado aos seis analisados - ODS 4, ODS 5, ODS 9, ODS 10, ODS 13 e ODS 14.

A população-alvo de estudo foi assim definida mas, havia ainda um outro ponto que necessitava de análise. Uma vez que a informação para os ODS está disponibilizada a nível mundial, no contexto da ONU, e a nível europeu, no contexto da EU foi importante analisar a forma como ambas as instituições têm estruturadas a informação e bases de dados para que fossem tidos em conta para o desenvolvimento dos modelos o que melhor se adequava ao objetivo proposto.

Tendo todos os requisitos apresentados em cima cumpridos, cada um dos 52 modelos foi desenvolvido. Posteriormente, foi feita uma avaliação à *performance* dos mesmos. Na sua generalidade, é possível afirmar que a escolha da abordagem foi positiva pois os resultados revelaram-se bastante válidos.

O grande benefício deste estudo é o de conseguir olhar ao futuro no presente, isto é, com os valores para cada indicador conhecido até 2030, Portugal tem uma margem de dez anos para tomar as medidas necessárias para reverter tendências e/ou mantê-las.

Considera-se que o objetivo principal foi cumprido, porém, sendo este estudo informativo caberá a quem de direito refletir sobre os resultados e, quem sabe, agir face aos mesmos.

6 Limitações

De notar que a forma como são apurados os valores ao longo dos anos, por parte da União Europeia, foram limitativos para alguns indicadores. Por exemplo, o indicador 5.1 - Mulheres que sofreram algum tipo de violência - não sofre qualquer alteração desde 2012 e está agrupado por faixas etárias o que impossibilita a sua previsão. Outro caso exemplificativo são os indicadores cujos valores apurados se basearam em inquéritos realizados à população pois acabam por ser muito ambíguos podendo não ter uma amostra considerável de respostas levando a que os valores possam não estar completos ou não serem 100% fidedignos.

Outro aspeto que deve ser mencionado diz respeito às metas estabelecidas, pois pressupõe-se que todos os indicadores em análise iriam ter uma associada, mas tal não se verificou. Tendo em conta esta limitação, apesar dos valores previstos elucidarem para progressos positivos não é possível fazer uma conclusão 100% segura.

7 Trabalhos Futuros

Uma vez realizadas as conclusões e apresentadas as limitações sentidas ao longo do estudo, é possível apresentar propostas de trabalhos futuros. Seguindo as mesmas linhas orientadoras seria interessante estudar-se mais formas de recolha de dados para os indicadores e alargar também o seu período de recolha. Atualmente, a apresentação e agregação dos dados é feita a nível anual contudo, caso se alargasse para um espectro mensal haveria mais histórico facilitando a realização de estudos de previsão bem como análises mais rigorosas. Tendo imagens mensais poderia ser mais fácil retirarem-se conclusões e definir-se estratégias uma vez que seria possível estudar-se sazonalidades.

Também no seguimento da dissertação e, tendo em conta o contexto atual vivido mundialmente com o *SARS-CoV-2* seria interessante estudar os impactos que cada indicador poderá sofrer e se alterará significativamente os progressos realizados. Dado que os valores dos indicadores do presente ano apenas serão conhecidos no início do próximo ano não foi possível quantificar o impacto do vírus.

Dentro do desenvolvimento de previsão de séries temporais, também poderia ser interessante tentar combinar uma abordagem estatística, como o ARIMA, com uma abordagem de aprendizagem automática, como o LSTM.

8 Referências

- Agency, C., Program, S., Affairs, P., Council, N. (2011). Sustainability and the U.S. EPA, Washington, DC: *The National Academic Press*. doi: 10.17226/13152.
- Ameyaw, B., Yao, L., 2018. Analyzing the Impact of GDP on CO2 Emissions and Forecasting Africa's Total CO2 Emissions with Non-Assumption Driven Bidirectional Long Short-Term Memory. *Sustainability* 10, 3110. <https://doi.org/10.3390/su10093110>
- Amin, M. A. A. and Hoque, M. A. (2019). Comparison of ARIMA and SVM for Short-term Load Forecasting. 9th Annual Information Technology, Electromechanical Engineering and Microelectronics Conference (IEMECON). 2019 9th Annual Information Technology, Electromechanical Engineering and Microelectronics Conference (IEMECON), pp. 1–6. doi: 10.1109/IEMECONX.2019.8877077.
- Aparicio, J. T., & Costa, C. J. (2020). Sustainability. OAE – Organizational Architect and Engineer Journal. V. 2, Issue 1. <https://doi.org/10.21428/b3658bca.6a4dc026>
- Aparicio, S., Aparicio, J. T., & Costa, C. J. (2019). Data Science and AI: trends analysis. In 2019 14th Iberian Conference on Information Systems and Technologies (CISTI) (pp. 1-6). IEEE.

- Armstrong, J. S. and Collopy, F. (1992). Error measures for generalizing about forecasting methods: Empirical comparisons. *International Journal of Forecasting*, 8(1), pp. 69–80. doi: 10.1016/0169-2070(92)90008-W.
- BCSD Portugal (2019). As marcas e a sustentabilidade [Em linha] Disponível em: <https://www.bcsdportugal.org/noticias/as-marcas-e-a-sustentabilidade> [Acesso em: 2020/04/27].
- Brown, B. J. et al. (1987). FORUM Global Sustainability: Toward Definition. *Environmental Management* 11(6), 713-719
- Costa, C. J., & Aparicio, J. T. (2020). POST-DS: A Methodology to Boost Data Science. In 2020 15th Iberian Conference on Information Systems and Technologies (CISTI) (pp. 1-6). IEEE.
- Duić, N., Urbaniec, K. and Huisingh, D. (2015). Components and structures of the pillars of sustainability. *Journal of Cleaner Production*, 88, pp. 1–12. doi: 10.1016/j.jclepro.2014.11.030.
- European Union (2020). Main tables - Eurostat [Base de Dados], 2020. Bruxelas: Eurostat. Disponível em: <https://ec.europa.eu/eurostat/web/sdi/main-tables> (Acesso em: 2020/10/18).
- European Union (2020). Sustainable development in the European Union — Monitoring report on progress towards the SDGs in an EU context (2020 edition) no. 4, Publications Office of European Union, Luxembourg.
- Faccioli, M. (2016). Do we care about sustainability? An analysis of time sensitivity of social preferences under environmental time-persistent effects. *Journal of Environmental Management*, p. 9.
- Flores, B. E. (1986). A pragmatic view of accuracy measurement in forecasting. *Omega*, 14(2), pp. 93–98. doi: 10.1016/0305-0483(86)90013-7.
- Glavič, P. and Lukman, R. (2007). Review of sustainability terms and their definitions. *Journal of Cleaner Production*, 15(18), pp. 1875–1885. doi: 10.1016/j.jclepro.2006.12.006.
- Han, J. H. (2018). *Comparing Models for Time Series Analysis*. University of Pennsylvania, Pennsylvania.
- Huck, N. 2009. Pairs selection and outranking: An application to the S&P 100 Index. *European Journal of Operational Research*, pp 820-825.
- Inter-agency and Expert Group SDG Indicators (IAEG-SDGs). (2020). Tier classification for global SDG indicators (17 July 2020), New York.

- Khandelwal, I., Satija, U. and Adhikari, R. (2015). Forecasting seasonal time series with Functional Link Artificial Neural Network. 2nd International Conference on Signal Processing and Integrated Networks (SPIN). 2015 2nd International Conference on Signal Processing and Integrated Networks (SPIN), pp. 725–729. doi: 10.1109/SPIN.2015.7095387.
- Le, X.-H., Ho, H.V., Lee, G., Jung, S., 2019. Application of Long Short-Term Memory (LSTM) Neural Network for Flood Forecasting. *Water* 11, 1387. <https://doi.org/10.3390/w11071387>
- Lee, D. et al. (2019). Syllable-Level Long Short-Term Memory Recurrent Neural Network-based Language Model for Korean Voice Interface in Intelligent Personal Assistants. IEEE 8th Global Conference on Consumer Electronics (GCCE). 2019 IEEE 8th Global Conference on Consumer Electronics (GCCE), pp. 289–290. doi: 10.1109/GCCE46687.2019.9015213.
- Makridakis, S. (1993). Accuracy measures: theoretical and practical concerns. *International Journal of Forecasting*, 9(4), pp. 527–529. doi: 10.1016/0169-2070(93)90079-3.
- Mujeeb, S., Javaid, N., Ilahi, M., Wadud, Z., Ishmanov, F., Afzal, M.K., 2019. Deep Long Short-Term Memory: A New Price and Load Forecasting Scheme for Big Data in Smart Cities. *Sustainability* 11, 987. <https://doi.org/10.3390/su11040987>
- Panapongpakorn, T. and Banjerdpongchai, D. (2019). Short-Term Load Forecast for Energy Management Systems Using Time Series Analysis and Neural Network Method with Average True Range. First International Symposium on Instrumentation, Control, Artificial Intelligence, and Robotics (ICA-SYMP). 2019 First International Symposium on Instrumentation, Control, Artificial Intelligence, and Robotics (ICA-SYMP), pp. 86–89. doi: 10.1109/ICA-SYMP.2019.8646068.
- Prema, V. and Rao, K.U. (2015). Development of statistical time series models for solar power prediction. Elsevier: *Renewable Energy*, vol. 83, pp. 100-109, DOI:10.1016/j.renene.2015.03.038.
- República Portuguesa – Negócios Estrangeiros, 2017. Relatório Nacional sobre a implementação da Agenda 2030 para o Desenvolvimento Sustentável, Pp 3-10.
- SDSN & IEEP. 2019. The 2019 Europe Sustainable Development Report. Sustainable Development Solutions Network and Institute for European Environmental Policy: Paris and Brussels.
- Shearer, C. (2000) The CRISP-DM Model: The New Blueprint for Data Mining, *Journal of Data Warehousing*, Volume 5, Number 4, page. 13-22.
- Siame-Namini, S., Tavakoli, N. and Siame Namin, A. (2018). A Comparison of ARIMA and LSTM in Forecasting Time Series. 17th IEEE International Conference on Machine Learning and Applications (ICMLA). 2018 17th IEEE.

- Smith, M. and Agrawal, R. (2000). A Comparison of Time Series Model Forecasting Methods on Patent Groups. North Carolina A&T State University, p. 7.
- United Nations – Economic and Social Council (2020). Progress towards the Sustainable Development Goals, United Nations, New York.
- United Nations (2015). Transforming our world: the 2030 Agenda for Sustainable Development: Sustainable Development Knowledge Platform (2015). [Em linha] Disponível em: <https://sustainabledevelopment.un.org/post2015/transformingourworld> (Acesso em: 2020/04/30).
- United Nations (2016) The Sustainable Development Goals Report 2016, New York: Department of Economic and Social Affairs (DESA), New York.
- Wang, Z., Osseweijer, P. and Duque, J. P. (2017). Assessing social sustainability for biofuel supply chains: The case of aviation biofuel in Brazil. IEEE Conference on Technologies for Sustainability (SusTech). 2017 IEEE Conference on Technologies for Sustainability (SusTech), pp. 1–5. Doi: 10.1109/SusTech.2017.8333474.
- Wu, L. et al. (2017). Short-term versus long-term benefits: Balanced sustainability framework and research propositions. SUSTAINABLE PRODUCTION AND CONSUMPTION, p. 13.
- Yan, W. (2012). Toward Automatic Time-Series Forecasting Using Neural Networks. IEEE Transactions on Neural Networks and Learning Systems, 23(7), pp. 1028– 1039. doi: 10.1109/TNNLS.2012.2198074.

9 Anexos

Anexo 1: Exemplo ficheiro CSV importado

	Ano	Percentagem
0	31/12/2000	43.7
1	31/12/2001	44.3
2	31/12/2002	45.0
3	31/12/2003	41.2
4	31/12/2004	39.3
5	31/12/2005	38.3
6	31/12/2006	38.5
7	31/12/2007	36.5
8	31/12/2008	34.9
9	31/12/2009	30.9
10	31/12/2010	28.3
11	31/12/2011	23.0
12	31/12/2012	20.5
13	31/12/2013	18.9
14	31/12/2014	17.4
15	31/12/2015	13.7
16	31/12/2016	14.0
17	31/12/2017	12.6
18	31/12/2018	11.8
19	31/12/2019	10.7

Figura 1: Ficheiro CSV – indicador 4.1 (ODS 4)

Fonte: Eurostat (2020)

Anexo 2: Exemplo Gráfico Evolutivo da Previsão

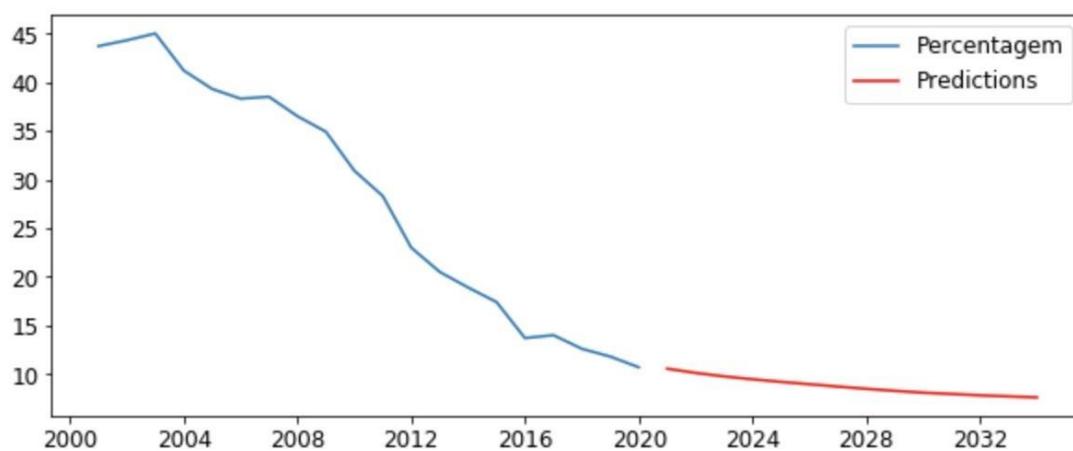


Figura 2: Gráfico evolutivo – indicador 4.1 (ODS 4)

Fonte: Próprio Autor

Anexo 3: Evolução do histórico de dados do ODS 4

Tabela XVIII
Evolução do histórico de dados dos indicadores do ODS 4

ODS	Descrição ODS	Indicador	Descrição Indicador	2000	2001	2002	2003	2004	2005	2006	2007	2008	2009	2010	2011	2012	2013	2014	2015	2016	2017	2018	2019	
4	Educação de Qualidade	4.1	Abandono precoce da educação	43,7	44,3	45	41,2	39,3	38,3	38,5	36,5	34,9	30,9	28,3	23	20,5	18,9	17,4	13,7	14	12,6	11,8	10,7	
		4.2	Abandono precoce da educação por cidadania					39,5	38,1	38,2	36,2	34,7	30,7	27,8	22,9	20,3	18,6	17,1	13,5	13,8	12,3	11,6	10,2	
		4.3	Nível educacional superior	11,1	11,6	12,9	14,7	16,3	17,5	18,3	19,5	21,6	21,3	24	26,7	27,8	30	31,3	31,9	34,6	33,5	33,5	35,5	
		4.4	Participação na educação infantil	76,6	79,3	80,3	82	82,8	84	84,5	87,9	88,7	90,1	91,2	93,8	95	93,9	93,5	93,6	92,5	94,2			
		4.5.1	Baixo aproveitamento escolar em literatura	26,3			21,9				24,9							18,8						20,2
		4.5.2	Baixo aproveitamento escolar em matemática				30,1				30,9			23,8				24,9			23,8			23,3
		4.5.3	Baixo aproveitamento escolar em ciências								24,5			16,5			19			17,4			19,6	
		4.6	Taxa de empregabilidade de recentes licenciados								83,1	81,2	82,8	82,4	80,6	75,8	67,5	67,8	69,4	72,2	73,8	80,7	80,6	
		4.7	Participação dos adultos na educação	3,3	3,2	2,8	3,2	4,2	4,1	4,2	4,4	5,3	6,4	5,7	11,5	10,5	9,7	9,6	9,7	9,6	9,8	10,3	10,3	

Fonte: Eurostat (2020)

Anexo 4: Evolução do histórico de dados do ODS 5

Tabela XIX
Evolução do histórico de dados dos indicadores do ODS 5

ODS	Descrição ODS	Indicador	Descrição Indicador	2000	2001	2002	2003	2004	2005	2006	2007	2008	2009	2010	2011	2012	2013	2014	2015	2016	2017	2018	2019	
5	Igualdade de Género	5.1	Violência física e sexual em mulheres																					
		5.2	Diferença salarial entre homens e mulheres								8,4	8,5	9,2	10	12,8	12,9	15	13,3	14,9	17,8	17,5	16,3	16,2	
		5.3	Gap de empregabilidade entre género	17,2	16,7	16,2	14,5	13,4	12,7	12,9	12,8	12,3	10,3	9,8	8,6	6,8	6,4	7,1	6,7	6,8	7,5	6,8		
		5.4	População inativa devido a responsabilidades de cuidadores	27,1	25,5	26,3	24,7	23,9	22,8	23,9	23,3	22,8	22,3	21,8	16,1	14,4	13,4	13,2	13,8	14,6	14,8	14,9		
		5.5.1	Proporção de lugares ocupados por mulheres no Parlamento				20,5	19,7	25,3	24,9	28,7	28,7	29,6	30,4	29,1	29,1	31,3	31,3	34,3	34,3	35,2	36,4	40,4	
		5.5.2	Proporção de lugares ocupados por mulheres no Governo				18,9	13,5	13	10,2	9,8	11,1	16,4	18,2	16,7	14,3	14,3	14,3	33,9	32,2	32,8	36,1	35,7	
		5.6.1	Proporção de cargos ocupados por mulheres como Membros do Conselho				3,5	4,1	6,1	6,8	3,2	2,6	3,7	5,4	5,9	7,4	8,8	9,5	13,5	14,3	16,2	21,6	24,6	
		5.6.2	Proporção de cargos ocupados por mulheres como Executivas														9,6	8	12,2	8	10,6	9	10	14,6
		5.7.1	Abandono precoce da educação sexo feminino	36,5	37	37,3	33,6	30,9	30,2	30,7	30	28,2	25,8	24	17,7	14	14,3	14,1	11	10,5	9,7	8,7	7,4	
		5.7.2	Abandono precoce da educação sexo masculino	50,9	51,6	52,7	48,7	47,6	46,2	46,1	42,8	41,4	35,8	32,4	28,1	26,9	23,4	10,7	16,4	17,4	15,3	14,7	13,7	
		5.8.1	Nível educacional superior sexo feminino	13,4	15	16,7	18,2	20,2	21,3	23,4	24,3	26,1	24,9	29,9	31,3	31	35,7	38,9	40,1	41,6	40,4	42,5	42,5	
		5.8.2	Nível educacional superior sexo masculino	8,9	8,2	9	11,1	12,4	13,5	13,1	14,7	16,9	17,6	17,9	21,8	24,3	24	23,2	23,3	27,3	26,2	24,1	29,7	
		5.9.1	Taxa de empregabilidade de recentes licenciados sexo feminino								80,9	79,5	80,2	80,2	79,1	73,6	64,6	66,6	69,7	70,9	71,4	79,5	80,6	79,2
		5.9.2	Taxa de empregabilidade de recentes licenciados sexo masculino								86,1	84,2	86,9	85,5	82,4	78,6	71,2	69,2	69	73,7	76,6	82,1	80,6	81,5

Fonte: Eurostat (2020)

Anexo 5: Evolução do histórico de dados do ODS 9

Tabela XX
Evolução do histórico de dados dos indicadores do ODS 9

ODS	Descrição ODS	Indicador	Descrição Indicador	2000	2001	2002	2003	2004	2005	2006	2007	2008	2009	2010	2011	2012	2013	2014	2015	2016	2017	2018	2019
9	Indústria, Inovação e Infraestruturas	9.1	Despesa nacional em R&D	0,7	0,8	0,7	0,7	0,7	0,8	1,0	1,1	1,4	1,6	1,5	1,5	1,4	1,3	1,3	1,2	1,3	1,3	1,4	
		9.2	Recursos humanos em ciência e tecnologia	17,2	17,4	17,5	18,1	21,1	21,4	21,9	22	23	23,5	23,9	26,9	28,7	30	33	34,8	36,2	36,4	37,5	38,3
		9.3	Pessoas em R&D	0,4	0,5	0,5	0,5	0,5	0,5	0,6	0,7	0,9	0,9	0,9	0,9	1,0	0,9	0,9	0,9	1,0	1,0	1,1	1,2
		9.4	Pedidos de Patentes ao Instituto Europeu de Patentes	42,0	42,5	39,5	66,7	58,5	122,9	106,5	123,8	117,1	92,2	95,1	121,0	112,2	118,8	126,8	137,4	139,1	142,2		
		9.5	Transporte de passageiros através de autocarros e comboios	18,3	17,2	15,1	14,9	14,9	10,7	10,4	10,6	10,8	10,6	10,9	10,8	10,5	10,6	10,2	11,1	11,6	11,5		
		9.6	Participação de ferrovias e hidroviás no transporte de carga						9,2	9	9,1	9,7	9,4	10,9	10,9	12,8	12,7	12,8	14,1	14,5	14,1	14,2	
		9.7	Emissões médias de CO2 por km, de novos passageiros	169,2		154	149,9	147,1	144,9	145	144,2	138,2	133,8	127,2	122,8	117,6	112,2	108,8	105,7	104,7	104,7	106,1	

Fonte: Eurostat (2020)

Anexo 6: Evolução do histórico de dados do ODS 10

Tabela XXI
Evolução do histórico de dados dos indicadores do ODS 10

ODS	Descrição ODS	Indicador	Descrição Indicador	2000	2001	2002	2003	2004	2005	2006	2007	2008	2009	2010	2011	2012	2013	2014	2015	2016	2017	2018	2019	
10	Redução de Desigualdades	10.1	PIB ajustado de poder de compra	15 700	16 200	16 700	17 100	17 600	18 500	20	20 300	20 700	20 000	20 700	20 000	19 500	20 100	20 600	21 300	22 000	22 600	23 000		
		10.2	Rendimento bruto familiar per capita	13 429	13 782	14 076	14 319	14 739	15 715	16 249	16 580	16 766	16 528	16 742	16 202	16 158	16 493	16 649	17 632	17 686	17 732	18 513		
		10.3	Mediana relativa do risco de pobreza	25	22			24,7	26	23,5	24,3	23,2	23,6	22,7	23,2	24,1	27,4	30,3	29	26,7	27	24,5		
		10.4	Distribuição de rendimento					7,0	7,0	6,7	6,5	6,1	6,0	5,6	5,7	5,8	6,0	6,2	6,0	5,9	5,8	5,2		
		10.5	Pedidos de asilo										15	13	15	26	28	48	42	84	69	99	121	
		10.6	Participação no rendimento de 40% da população mais pobre	19	18			17,8	17,9	18,3	18,4			19,2	19,7	19,6	19,6	19,4	19	19,4	19,4	19,9	20,5	
		10.7	Pessoas em risco de pobreza depois de pagamento de encargos					19,2	18,3	17,8	17,5	17,6	16,8	16,9	16,6	16,8	17,2	17,9	18,1	18	17,7	16,9	16,9	
		10.8	Abandono precoce da educação	43,7	44,3	45	41,2	39,3	38,3	38,5	36,5	34,9	30,9	28,3	23	20,5	18,9	17,4	13,7	14	12,6	11,8	10,7	
		10.9	Jovens que não trabalham nem estudam					11,8	12,2	11,9	12,4	11,7	11,9	12,9	13,6	15,5	16,2	14,5	12,8	12,4	10,3	9,5	9	
		10.10	Empregabilidade por cidadania	73,4	74	74	73	72,6	72,1	72,5	72,4	72,8	71,1	70,4	68,9	66,4	65,6	67,7	69,2	70,7	73,5	75,4	76,2	

Fonte: Eurostat (2020)

Anexo 7: Evolução do histórico de dados do ODS 13

Tabela XXII
Evolução do histórico de dados dos indicadores do ODS 13

ODS	Descrição ODS	Indicador	Descrição Indicador	2000	2001	2002	2003	2004	2005	2006	2007	2008	2009	2010	2011	2012	2013	2014	2015	2016	2017	2018	2019	
13	Ação Climática	13.1	Emissões Efeto de Estufa	138,8	138	144,3	135,9	141,2	145	137,4	133,9	130	124,5	118	115,8	112,8	109,8	110,1	117	114,4	122,8			
		13.2	Intensidade de emissões de efeito de estufa do consumo de energia	100	99,5	101,1	95,6	96,1	97,3	95,2	90	88,9	88,3	83,5	84,5	87	82,9	80,8	85,4	83,6	86,8			
		13.3	Perdas económicas relacionadas com o clima - Agregado EU	20 600	3 975	29 879	20 927	3 247	14 988	5 674	17 536	5 447	9 251	19 539	7 471	4 870	22 976	11 667	11 465	9 769	12 052			
		13.4	Contribuição para o compromisso internacional de 100 biliões de dólares para o clima																9,52	6,22	2	2,17		
		13.5	Participação das energias renováveis nos gastos totais de consumo energético					19,2	19,5	20,8	21,9	22,9	24,4	24,2	24,6	24,6	25,7	29,5	30,5	30,9	30,3			
		13.6	Emissões médias de CO2 por km, de novos passageiros	169,2		154	149,9	147,1	144,9	145	144,2	138,2	133,8	127,2	122,8	117,6	112,2	108,8	105,7	104,7	104,7	106,1		
		13.7	Mean near-surface temperatura deviation	0,61	0,76	0,82	0,83	0,77	0,87	0,83	0,81	0,72	0,83	0,88	0,75	0,79	0,83	0,9	1,08	1,12	1	0,92		
		13.8	População abrangida pela Covenant of Mayors for Climate & Energy												2825	1761	1918	2419	5444	5978	6025	616	6184	6537
		13.9	Acidez média global da superfície do oceano	8,09	8,09	8,08	8,08	8,08	8,08	8,09	8,08	8,07	8,07	8,07	8,07	8,07	8,07	8,07	8,07	8,06	8,06	8,06	8,06	8,06

Fonte: Eurostat (2020)

Anexo 8: Evolução do histórico de dados do ODS 14

Tabela XXIII
Evolução do histórico de dados dos indicadores do ODS 14

ODS	Descrição ODS	Indicador	Descrição Indicador	2000	2001	2002	2003	2004	2005	2006	2007	2008	2009	2010	2011	2012	2013	2014	2015	2016	2017	2018	2019		
14	Proteção da Vida Marinha	14.1	Superfícies de locais marinhos designados sob NATURA 2000												1 756	2 408	2 619	2 634	31 885	31 885	38 052	38 052			
		14.2	Tendência estimada do stock de peixes no Atlântico Nordeste																						
		14.3	Stock de peixe avaliados excedem a taxa de mortalidade no Atlântico Nordeste																						
		14.4.1	Locais de banho com excelente qualidade de água - Águas Costeiras													431	437	446	452	460	464	480	480		
		14.4.2	Locais de banho com excelente qualidade de água - Águas Interiores													83	89	97	106	109	115	123	128		
		14.5	Acidez média global da superfície do oceano	8,09	8,09	8,08	8,08	8,08	8,08	8,09	8,08	8,07	8,07	8,07	8,07	8,07	8,07	8,07	8,07	8,06	8,06	8,06	8,06	8,06	

Fonte: Eurostat (2020)

