



Pós-Graduação em Ciência da Computação

LUCAS MINORU FERREIRA HARADA

**PROPOSTA DE UM MECANISMO DINÂMICO DE SELEÇÃO DE
INTERFACE DE REDE DE DISPOSITIVOS MÓVEIS UTILIZANDO
APRENDIZAGEM DE MÁQUINA**



Universidade Federal de Pernambuco
posgraduacao@cin.ufpe.br
www.cin.ufpe.br/~posgraduacao

Recife
2017

LUCAS MINORU FERREIRA HARADA

**PROPOSTA DE UM MECANISMO DINÂMICO DE SELEÇÃO DE
INTERFACE DE REDE DE DISPOSITIVOS MÓVEIS UTILIZANDO
APRENDIZAGEM DE MÁQUINA**

Este trabalho foi apresentado à Pós-Graduação em Ciência da Computação do Centro de Informática da Universidade Federal de Pernambuco como requisito parcial para obtenção do grau de Mestre em Ciência da Computação.

Área de Concentração: Comunicações Móveis

Orientador(a): Daniel Carvalho da Cunha

Recife
2017

Catálogo na fonte
Bibliotecária Mariana de Souza Alves CRB4-2106

H254p Harada, Lucas Minoru Ferreira
Proposta de um Mecanismo Dinâmico de Seleção de Interface de Rede de Dispositivos Móveis Utilizando Aprendizagem de Máquina – 2017.
53f.: il., fig., tab.

Orientador: Daniel Carvalho da Cunha
Dissertação (Mestrado) – Universidade Federal de Pernambuco. CIn, Ciência da computação. Recife, 2017.
Inclui referências e apêndice.

1. Comunicações Móveis. 2. Dispositivos Móveis. 3. Consumo de Energia. 4. Seleção Dinâmica de Interface de Rede. I. Cunha, Daniel Carvalho da (orientador). II. Título.

004

CDD (22. ed.)

UFPE-MEI 2019-151

Lucas Minoru Ferreira Harada

**Proposta de um Mecanismo Dinâmico de Seleção de Interface
de Rede de Dispositivos Móveis Utilizando Aprendizagem de
Máquina**

Dissertação de Mestrado
apresentada ao Programa de Pós-
Graduação em Ciência da
Computação da Universidade
Federal de Pernambuco, como
requisito parcial para a obtenção do
título de Mestre em Ciência da
Computação

Aprovado em: 17/02/2017

BANCA EXAMINADORA

Prof. Dr. Abel Guilhermino da Silva Filho
Centro de Informática / UFPE

Prof. Dr. Francisco Madeiro Bernardino Junior
Escola Politécnica de Pernambuco/UPE

Prof. Dr. Daniel Carvalho da Cunha
Centro de Informática / UFPE
(Orientador)

Dedico esta dissertação para toda minha família, amigos e professores que me deram todo o suporte necessário.

AGRADECIMENTOS

À Fernanda Castro, pelo amor, companheirismo e confiança imensuráveis.

Aos meus pais, pelo apoio e oportunidades que me foram dadas e continuam a dar.

Aos meus sogros, pelo apoio e incentivo dado.

Aos Brokerinos, pelos momentos de descontração e amizade.

À minha família e meus amigos, pelo incentivo dado.

Ao meu orientador Daniel Cunha, pelo conhecimento que me foi passado e direcionamento que possibilitou este trabalho.

RESUMO

Nas últimas décadas, as comunicações móveis evoluíram de um patamar de tecnologia cara utilizada por alguns poucos indivíduos para a condição de sistemas ubíquos usados pela maioria da população mundial. Diante desse cenário, as tecnologias presentes nos dispositivos móveis (hardware, software, comunicações e bateria) precisam evoluir para suprir as novas funcionalidades (altas taxas de dados e conectividade ininterrupta, por exemplo) que cada vez mais demandam um maior consumo de energia e, conseqüentemente, implicam na diminuição da autonomia dos smartphones. Sabendo que a tecnologia de transmissão sem fio contribui significativamente para o aumento do consumo de energia dos dispositivos móveis e considerando o crescimento exorbitante de tráfego de dados dos últimos anos, esforços têm sido realizados para se buscar soluções que estendam a autonomia das baterias. Um exemplo é a integração de diferentes tipos de redes sem fio (3G e Wi-Fi, por exemplo) que permitam ao dispositivo móvel selecionar a interface de rede com base em algum critério de otimização, como, por exemplo, a minimização do custo energético por cada byte transferido. Atualmente, em smartphones Android, sempre que redes Wi-Fi estão disponíveis, a interface de rede Wi-Fi do dispositivo móvel é naturalmente escolhida, muito provavelmente por questões financeiras. No entanto, tal escolha não garante que o consumo de energia associado será otimizado. Face ao exposto, o objetivo deste trabalho é a proposição de um mecanismo dinâmico de seleção de interface de rede focado em minimizar o consumo de energia do dispositivo móvel, permitindo um aumento da autonomia da bateria. Para isso, diversas técnicas de Aprendizagem de Máquina são empregadas no intuito de prever o custo energético por byte transferido de cada tipo de interface de rede disponível. Por fim, uma comparação dos custos energéticos (para cada interface de rede) obtidos por cada técnica de Aprendizagem de Máquina é realizada para indicar qual a melhor alternativa dentre as técnicas selecionadas. Dessa forma, é possível comparar as estimativas dos custos energéticos de cada interface e escolher aquela que diminui o consumo.

Palavras-chave: Dispositivos Móveis. Consumo de Energia. Comunicações Móveis. Seleção Dinâmica de Interface de Rede. Aprendizagem de Máquina.

ABSTRACT

On the last decades, mobile communications rose from a costly technology which few people could use to a ubiquitous systems used by most of people. On this, the technologies found on mobile devices (such as hardware, software, communications and battery) need to evolve to supply the new features (high data rate and continuous connectivity, for example) that demands a higher energy consumption and, consequently, imply on reduction of the smartphone's battery duration. Knowing that the wireless communication contribute fairly to the energy consumption of mobile devices and considering the huge increase of network traffic on the last years, efforts have been made to find solutions to extend battery duration. One example is the integration between different wireless networks types (e.g. 3G and Wi-Fi) that allows the device to select which network interface should be used based on some optimization criteria, like the minimization of the energy cost for each transferred byte. Currently, on Android smartphones, the Wi-Fi network is chosen every time it is available, probably because of monetary issue. However, this choice doesn't guarantee that the energy consumption will be minimized. Against the above, the objective of this dissertation is the proposition of a network interface dynamic selection mechanism focused on minimizing the mobile device's energy consumption, increasing the battery duration. To that, several Machine Learning techniques are applied to predict the energy cost for each transferred byte of each available network interface. Lastly, a comparison between all predicted energy costs (of each network interface) is performed to define which technique delivers the best performance. That way, it is possible to compare the energy cost estimates for each network interface and select the one that decreases the energy consumption

Keywords: Mobile Devices. Energy Consumption. Mobile Communications. Network Interface Dynamic Selection. Machine Learning.

LISTA DE FIGURAS

Figura 1 –	Diagrama da integração (áreas de cobertura) das redes celulares e Wi-Fi	13
Figura 2 –	Histograma relativo à característica comprimento para as categorias salmão (preto) e robalo (vermelho). Adaptado de (DUDA; HART; STORK, 2000)	17
Figura 3 –	Histograma relativo à característica claridade para as categorias salmão (preto) e robalo (vermelho). Adaptado de (DUDA; HART; STORK, 2000)	17
Figura 4 –	Gráfico de dispersão relativo à claridade e largura. A linha que divide as amostras é a que minimiza o erro de classificação. Adaptado de (DUDA; HART; STORK, 2000)	18
Figura 5 –	Gráfico de dispersão contendo a função de regressão linear. Adaptado de (CHATTERJEE; HADI, 2006)	20
Figura 6 –	Gráfico de dispersão contendo a função de regressão linear. Adaptado de (CHATTERJEE; HADI, 2006)	21
Figura 7 –	Processo de treinamento de um regressor	25
Figura 8 –	Exemplo de árvore de decisão como classificador e regressor	26
Figura 9 –	Regiões de decisão obtidas pela aplicação do algoritmo KNN (K=1) em um problema de classificação. As regiões em cinza indicam a classe vermelha, enquanto as regiões em branco indicam a classe preta. Adaptado de (DUDA; HART; STORK, 2000)	28
Figura 10 –	Mecanismo proposto de seleção dinâmica de interfaces de rede	34
Figura 11 –	Simulação da estimativa do custo energético por byte transferido para as interfaces de rede Wi-Fi e 3G	45
Figura 12 –	Simulação da estimativa da energia consumida instantânea para os mecanismos de seleção proposto e nativo	46
Figura 13 –	Simulação da estimativa do energia consumida acumulada para os mecanismos de seleção proposto e nativo	47

LISTA DE TABELAS

Tabela 1 –	Exemplo de um problema de regressão, onde cada registro contém a duração da chamada (minutos) e a quantidade de equipamentos reparados (unidades)	19
Tabela 2 –	Exemplo das árvores de decisão de um modelo <i>Random Forest</i> ($N=3$, $M=4$)	27
Tabela 3 –	Contribuições dos trabalhos relacionados a seleção de interfaces de rede.....	33
Tabela 4 –	Descrição do dispositivo móvel sob testes.....	35
Tabela 5 –	Características coletadas pelo uso do aplicativo não-comercial.	35
Tabela 6 –	Análise de características relativas à utilização da interface de rede Wi-Fi	39
Tabela 7 –	Análise de características relativas à utilização da interface de rede 3G	39
Tabela 8 –	Intervalos de caracterização de potência de sinal de RF (em dBm)	39
Tabela 9 –	Características coletadas e <i>ranking</i> gerado pelo algoritmo RFE	40
Tabela 10 –	Desempenho dos regressores para <i>download</i> em rede Wi-Fi	41
Tabela 11 –	Desempenho dos regressores para <i>streaming</i> em rede Wi-Fi.....	42
Tabela 12 –	Comparação das ordens de grandeza dos custos energéticos real e estimado pelos regressores para a interface de rede Wi-Fi (atividade de <i>download</i>)	42
Tabela 13 –	Desempenho dos regressores para <i>download</i> em rede 3G.....	43
Tabela 14 –	Desempenho dos regressores para <i>streaming</i> em rede 3G.....	44
Tabela 15 –	Comparação das ordens de grandeza das eficiências energéticas real e estimada pelos regressores para a interface de rede 3G (atividade de <i>download</i>)	44

LISTA DE ABREVIATURAS E SIGLAS

EMA	Erro Médio Absoluto
EMnA	Erro Mediano Absoluto
EMQ	Erro Médio Quadrático
GPR	Gaussian Process Regression
K-NN	K-Nearest Neighbors
LARS	Least Angle Regression
MLP	Multi-layer Perceptron
NN	Nearest Neighbors
OLS	Ordinary Least Squares
RNA	Redes Neurais Artificiais
SVR	Support Vector Regressor

SUMÁRIO

1	INTRODUÇÃO	12
1.1	<i>Motivação e Objetivos do Trabalho</i>	12
1.2	<i>Organização da Dissertação</i>	14
1.3	<i>Resumo das Principais Contribuições</i>	14
2	CONCEITOS BÁSICOS SOBRE APRENDIZAGEM DE MÁQUINA .15	
2.1	<i>Introdução</i>	15
2.2	<i>Exemplos de Problemas de Classificação e Regressão</i>	16
2.2.1	Classificação	16
2.2.2	Regressão	19
2.3	<i>Avaliação de Modelos</i>	21
2.4	<i>Modelos de Regressão</i>	24
2.4.1	Regressão Linear	25
2.4.2	Regressão usando Máquina de Vetor de Suporte	25
2.4.3	Random Forest	25
2.4.4	Nearest Neighbors	27
2.4.5	Regressão por Processo Gaussiano	29
2.4.6	Multi-layer Perceptron	29
3	SELEÇÃO INTELIGENTE DE INTERFACES DE REDE	31
3.1	<i>Introdução</i>	31
3.2	<i>Mecanismo Dinâmico Proposto</i>	33
3.2.1	Medições do smartphone	34
3.2.2	Metodologia Empregada	37
3.2.3	Resultados Numéricos	38
4	CONCLUSÃO	48
	REFERÊNCIAS	49
	APÊNDICE A – PARÂMETROS DOS MODELOS DE REGRESSÃO	53

1 INTRODUÇÃO

1.1 Motivação e Objetivos do Trabalho

Nas últimas décadas, as comunicações móveis evoluíram de um patamar de tecnologia cara utilizada por alguns poucos indivíduos para a condição de sistemas ubíquos usados pela maioria da população mundial. Segundo a Ericsson, empresa multinacional do ramo de telecomunicações, estima-se que, em 2020, 90% da população mundial acima dos seis anos de idade possuirá um *smartphone* (denominação atual dos telefones celulares de última geração) (ERICSSON, 2016). Ainda de acordo com a Ericsson, foi constatado que, em 2016, o número de assinaturas móveis atingiu a marca dos 7,5 bilhões, superando o número de habitantes do planeta (ERICSSON, 2016).

Diante desse cenário, as tecnologias presentes nos dispositivos móveis (hardware, software, comunicações e bateria) precisam evoluir para atender ao desejo dos usuários, ávidos por novas funcionalidades, tais como altas taxas de dados, opções de entretenimento (jogos e recursos de multimídia) e conectividade ininterrupta. No entanto, essas novas funcionalidades criam uma demanda crescente por componentes que exigem maior consumo de energia, como, por exemplo, maiores capacidades de armazenamento (memórias interna e auxiliar), além de processadores mais poderosos. Com isso, as novas funcionalidades desejadas pelos usuários contribuem para o aumento do consumo da bateria dos *smartphones*.

No que se refere ao avanço das tecnologias mencionadas, sabe-se que o aumento de desempenho dos processadores dobra a cada 18 meses (Lei de Moore), enquanto a taxa de transmissão em redes celulares praticamente dobra a cada 8,5 meses (SHEARER, 2007). Por outro lado, segundo (GONZALEZ, 2016), a tecnologia de baterias íon-lítio, amplamente utilizada atualmente, progride de forma lenta, onde sua densidade de energia aumenta em torno de 5% ao ano. Dessa forma, as baterias não apresentam o crescimento de capacidade capaz de sustentar as demandas por energia exigidas pelas novas aplicações (PERRUCCI; FITZEK; WIDMER, 2011).

O consumo de potência é o fator limitante para as funcionalidades oferecidas por dispositivos móveis que operam com baterias. Um dispositivo móvel que fornece altas taxas de transmissão de dados requer maior consumo de potência, não apenas em função do processamento, mas também pelo envio de sinais de rádio frequência (RF). Nesse aspecto, cada tecnologia de transmissão específica possui requisitos de consumo que geram impactos na duração da bateria (RUMNEY, 2013). Em termos práticos, dispositivos móveis modernos não são capazes de permanecer ligados 24 horas sem a necessidade de recarga: a empresa responsável pela venda do iPhone 7 declara que o tempo de uso de Internet para o aparelho é de até 14h com redes Wi-Fi e 12h com redes celulares¹.

Outro ponto importante relacionado à tecnologia de transmissão utilizada é o crescimento exorbitante do tráfego de dados nos últimos anos. Previsões da Cisco, outra empresa do ramo, apontam que o tráfego global de dados IP vai atingir 2,3 ZB (1 ZB $\approx 10^{21}$ bytes) em 2020 (CISCO SYSTEMS, 2016). Para lidar com essa questão, o *3rd Generation Partnership Project*, órgão responsável pela padronização das

¹ <http://www.apple.com/br/iphone-7/specs/>

tecnologias de telecomunicações no mundo, iniciou, em 2012, estudos sobre a possibilidade de se integrar as redes celulares (3G ou LTE) com redes Wi-Fi (3GPP, 2012). A Figura 1 ilustra um cenário de integração dos dois tipos de rede (celular e Wi-Fi), em que o círculo maior (com linha completa) representa a área de cobertura de uma célula da rede de telefonia celular, enquanto os círculos menores (com linha tracejada), representam a área de cobertura dos pontos de acesso das redes Wi-Fi. Neste cenário, a rede celular forma uma macrorregião, enquanto as redes Wi-Fi criam microrregiões de maior tráfego. Esta configuração permite que a rede celular seja complementada pelas redes Wi-Fi, diminuindo a carga e aumentando a capacidade de tráfego total da rede. Em locais onde houver disponibilidade de ambas as redes (área em branco), os dispositivos móveis são capazes de escolher qual interface de rede utilizar, com base em diversos fatores, tais como largura de banda necessária ou eficiência energética.

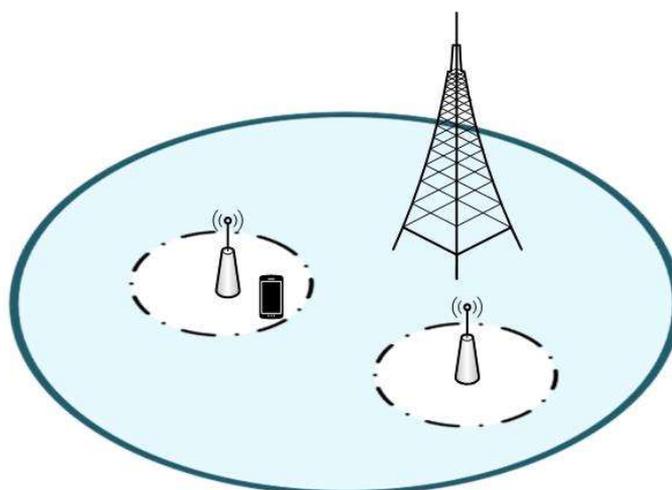


Figura 1 – Diagrama da integração (áreas de cobertura) das redes celulares e Wi-Fi

Atualmente, a decisão sobre qual interface de rede escolher é feita de maneira rígida. Em *smartphones* Android, não existe nenhum modelo real de seleção de interfaces de rede: a decisão de qual interface de rede utilizar é preferir as redes Wi-Fi sempre que estas estiverem disponíveis. Tal decisão comumente resulta em desempenho ruim em situações cotidianas como, por exemplo, estar em movimento para sair de uma edificação ou, dentro de uma edificação, estar parado no cômodo mais distante do ponto de acesso Wi-Fi. Em ambas as situações, é provável que utilizar a rede celular seja mais vantajoso tanto para o desempenho quanto para o consumo energético. Dessa forma, a seleção de interface de rede em dispositivos móveis deve ser uma tarefa de caráter dinâmico.

Dispositivos móveis (*smartphone*) têm sido um *hot spot* na comunidade científica com diferentes focos, como compreensão do consumo energético em *smartphones* (BORNHOLT; MYTKOWICZ; MCKINLEY, 2012), geração de modelos energéticos para *smartphones* (LI, 2014) ou otimização de funcionalidades (ALTAMIMI, 2012). Dentro do escopo de técnicas de otimização aplicadas a dispositivos móveis, diversos pesquisadores têm atuado em mecanismos de seleção inteligente de interfaces de rede, com objetivo de aprimorar a utilização da largura da banda ou a eficiência energética.

Esta última abordagem de otimização se baseia no fato de diferentes interfaces de rede consumirem valores significativamente distintos de energia (ANDREUCETTI, 2014).

Face ao exposto, esta dissertação tem o objetivo de propor um mecanismo dinâmico de seleção de interface de rede focado em minimizar o consumo de energia do dispositivo móvel, permitindo um aumento da vida útil da bateria. Para atingir o objetivo proposto, algoritmos de Aprendizagem de Máquina são empregados no intuito de prever o custo energético por *byte* de cada tipo de interface de rede disponível. Ao final, uma comparação dos custos energéticos por *byte* obtidos por cada técnica de Aprendizagem de Máquina é realizada para indicar qual a melhor alternativa dentre as selecionadas.

1.2 Organização da Dissertação

Nesta Seção, foi introduzido o problema de consumo de energia em *smartphones* e como o problema de seleção de interface de rede se aplica para melhorar a vida útil da bateria de dispositivos móveis. Na Seção 2, são apresentados conceitos básicos de Aprendizagem de Máquina, uma ferramenta computacional utilizada neste trabalho, assim como diferenças entre classificação e regressão, metodologia de avaliação de Aprendizagem de Máquina e, por fim, apresentação dos modelos utilizados. Na Seção 3, é apresentada uma revisão da literatura acerca do tema seleção inteligente de interfaces de rede, seguida das condições experimentais, metodologia empregada e os resultados numéricos que ratificam o mecanismo de seleção inteligente de interface de rede proposto. Por fim, a Seção 4 conclui a dissertação e discute possíveis direções para trabalhos futuros.

1.3 Resumo das Principais Contribuições

As principais contribuições desta dissertação foram:

1. Até onde sabemos, nossa metodologia para a seleção da melhor interface de rede é a única que tenta estimar o consumo energético previamente. Dessa maneira, o problema é tratado como um problema de regressão, uma categoria de algoritmos de Aprendizagem de Máquina, onde diversos modelos de regressão são testados para selecionar o melhor entre eles.

2. Diferentemente de diversos trabalhos na área, nosso trabalho trará a utilização de dados reais para o treinamento dos modelos de regressão. As comparações do consumo final de energia serão feitas com uma análise teórica baseada em dados de comportamento real de uso do *smartphone*.

3. O método proposto não requer nenhuma modificação em qualquer aplicação ou no sistema operacional do *smartphone*. Desta forma, essa solução pode ser implementada rapidamente.

2 CONCEITOS BÁSICOS SOBRE APRENDIZAGEM DE MÁQUINA

Aprendizagem de Máquina tem se tornado uma ferramenta bastante utilizada não só pela comunidade científica como também por grandes empresas. Entre suas utilizações comerciais estão sistemas de recomendação, como os utilizados pela Amazon e Netflix, sistemas de reconhecimento de fraude, como os utilizados pelo PayPal, por exemplo. Na comunidade científica, Aprendizagem de Máquina tem sido aplicada em pesquisas sobre câncer (KOLAY; ERDOGMUS, 2016), carros inteligentes (ZHAO, 2016), entre outros. Esta Seção aborda conceitos básicos sobre Aprendizagem de Máquina, ferramenta computacional utilizada no desenvolvimento deste trabalho. Exemplos de problemas de classificação e regressão, adaptados de (DUDA; HART; STORK, 2000) e (CHATTERJEE; HADI, 2006), respectivamente, são apresentados. Com foco em regressão, uma metodologia de avaliação de modelos é abordada, assim como as métricas utilizadas na análise dos modelos de regressão. Por fim, os modelos de regressão aplicados neste trabalho são apresentados.

2.1 Introdução

Classificar um objeto é uma tarefa bastante comum aos seres humanos, seja por meio de sua visão, tato ou olfato, por exemplo. Imagine um problema onde é necessário distinguir maçãs saudáveis de maçãs podres. A princípio, esta é uma tarefa fácil para qualquer pessoa, mas automatizar esta tarefa não o é. Para tornar esta tarefa automática, é necessário criar regras para que uma máquina possa analisar e tomar sua decisão. Entretanto, quais devem ser os critérios para considerar uma maçã saudável? Seu peso, consistência, cor, cheiro ou uma combinação de todos esses fatores? Este é o problema conhecido por classificação, no qual se atribui um novo objeto a uma determinada classe previamente conhecida. Um classificador (ser humano ou máquina) deve analisar o novo objeto baseado em experiências anteriores e assim, decidir a qual classe o objeto pertence.

Por outro lado, considere a possibilidade de se medir o nível de oxidação sofrida por um conjunto de maçãs através de um equipamento, mas que é necessário estimar esse nível para futuras maçãs a partir de suas características. Este é um problema de regressão, onde se busca estimar um valor contínuo a partir de um conjunto de características do objeto. Assim, classificação e regressão são dois dos tipos de problemas centrais dentro do escopo de Aprendizagem de Máquina, onde ambos buscam prever um atributo a partir de características conhecidas do objeto. Inclusive, classificação e regressão são categorias de problemas de Aprendizagem de Máquina que podem ser relacionadas. Por exemplo, se voltarmos ao problema de classificar maçãs saudáveis e podres, a criação de um limiar (e.g., considerar podre maçãs com nível de oxidação maior que 65%) torna o problema de regressão em um problema de classificação.

De um modo geral, os algoritmos de Aprendizagem de Máquina funcionam da seguinte forma: um **modelo** é gerado a partir de um **conjunto de treinamento** (dados que serão utilizados como parâmetro) com **características específicas** (*features*) de um problema para ser aplicado em dados reais (que não são previamente conhecidos), buscando se obter o melhor desempenho possível. A fase de treinamento

do modelo tem o intuito de diminuir a taxa de erros naquele grupo de dados para que ele seja aplicado posteriormente em dados reais.

Segundo (ALPAYDIN, 2014), Aprendizagem de Máquina é a programação de computadores com o objetivo de otimizar um critério de desempenho utilizando dados de exemplo ou experiências anteriores. Em outras palavras, a partir de um modelo definido por certos parâmetros, a aprendizagem é a execução de um algoritmo visando otimizar seus parâmetros a partir de dados de treinamento ou experiências passadas. Este modelo pode ser **preditivo** (para prever o futuro), **descritivo** (para ganhar conhecimento a partir dos dados) ou **híbrido**. Há também diversos outros fatores que diferenciam as técnicas de Aprendizagem de Máquina, como o método de aprendizagem e o tipo do problema.

Em relação à técnica de aprendizagem, (DUDA; HART; STORK, 2000) divide Aprendizagem de Máquina em três categorias: aprendizagem supervisionada, onde todos os dados de treinamento fornecidos são previamente classificados por um agente externo, chamado professor ou oráculo, e os dados categorizados são utilizados para classificar dados futuros; aprendizagem não-supervisionada (também conhecido como (*clustering*)), onde nenhum dado de treinamento é previamente classificado e grupos de dados (*clusters*) parecidos entre si são gerados; e, finalmente, aprendizagem por reforço que, diferentemente da aprendizagem supervisionada, contém a presença de um professor que indica apenas se a tentativa da técnica é correta ou errada.

Os algoritmos de Aprendizagem de Máquina também podem ser categorizados pelo tipo do problema a ser resolvido. A principal diferença entre um problema de classificação e um problema de regressão é que a resposta dos problemas de regressão está contida em um conjunto contínuo de valores, enquanto a resposta de um problema de classificação se resume a um conjunto discreto (conjunto de classes). Isto significa que enquanto o problema de classificação tenta encontrar a classe correta para um dado objeto, o problema de regressão quantifica uma variável e retorna esse valor como resposta.

2.2 Exemplos de Problemas de Classificação e Regressão

2.2.1 Classificação

Suponha que uma indústria de enlatamento de peixes está em processo de automatização e precisa separar tipos diferentes de peixes (robalo e salmão, no caso) utilizando sensores óticos. A partir dos sensores óticos, é possível obter comprimento, claridade, largura, posição da boca, quantidade e formato das nadadeiras dos peixes. Como robalos e salmões são peixes diferentes, existe um modelo que descreve cada um deles. O objetivo da Aprendizagem de Máquina é encontrar uma aproximação razoável destes modelos para então classificar uma nova amostra entre as duas possibilidades.

As Figuras 2 e 3 mostram os histogramas relativos ao comprimento e à claridade dos peixes, respectivamente, assim como os valores l^* e x^* que minimizam a quantidade de erros de classificação em cada histograma. É possível notar que não existe nenhum valor que divida as duas classes sem a presença de erros, considerando as duas características individualmente. Por exemplo, não existe um valor limiar onde todos os peixes de comprimento maior que l^* sejam de uma classe e aqueles cujo comprimento é menor do que l^* seja da outra classe. Entretanto, analisando as

características individualmente, a claridade é um critério que discrimina os tipos de peixe melhor do que o comprimento, mas ainda apresenta valores de erro altos.

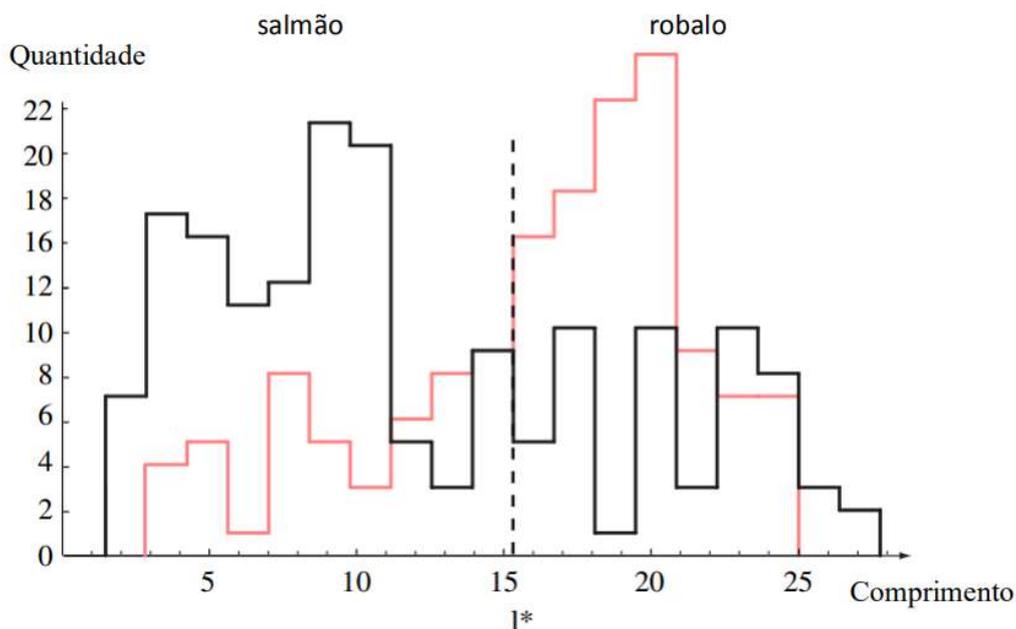


Figura 2 – Histograma relativo à característica comprimento para as categorias salmão (preto) e robalo (vermelho). Adaptado de (DUDA; HART; STORK, 2000)

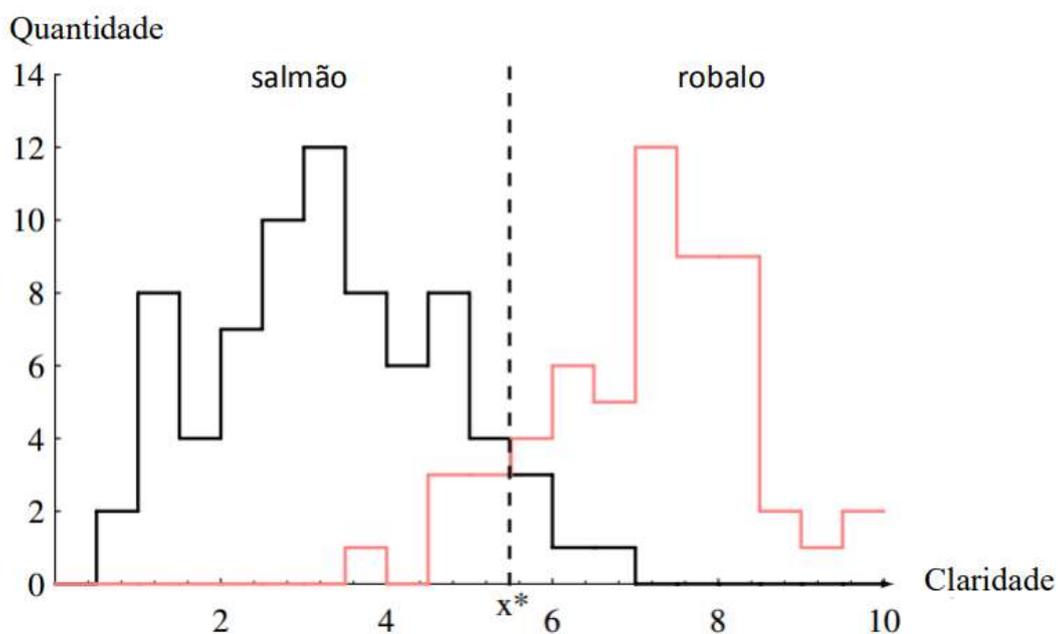


Figura 3 – Histograma relativo à característica claridade para as categorias salmão (preto) e robalo (vermelho). Adaptado de (DUDA; HART; STORK, 2000)

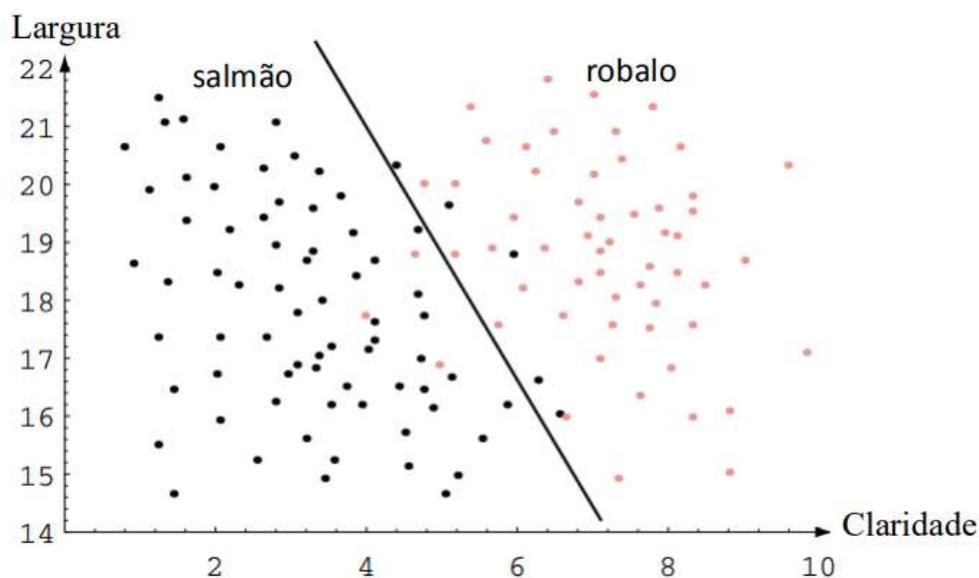


Figura 4 – Gráfico de dispersão relativo à claridade e largura. A linha que divide as amostras é a que minimiza o erro de classificação. Adaptado de (DUDA; HART; STORK, 2000)

Após análise de todas as características, a empresa decidiu que aquelas a serem levadas em conta seriam a largura e a claridade, descartando o comprimento. A Figura 4 mostra o gráfico de dispersão considerando as características escolhidas. Ao analisar largura e claridade conjuntamente, fica evidente que existe uma linha de separação que diminui o erro de classificação em relação à análise das características individuais, como mostrada na Figura 4.

Dessa forma, ao se analisar um peixe, é suficiente que os sensores da máquina de enlatamento verifiquem somente sua claridade e sua largura. Como o problema está em um espaço de características bidimensional, basta comparar a posição relativa do ponto em relação a reta de separação das classes. Se o ponto estiver acima da reta de separação, ele é classificado como robalo; caso contrário, é classificado como salmão.

2.2.2 Regressão

Considere que uma companhia de venda e consertos de computadores deseja descobrir qual a relação entre a duração da ligação telefônica para seu serviço de atendimento e a quantidade de componentes do computador que precisa ser reparada. Para tal, uma amostra de 14 registros de chamadas de atendimento foi analisada. A Tabela 1 apresenta os dados referentes à duração da chamada (em minutos) e a quantidade de componentes reparados (em unidades).

Neste exemplo, o objetivo da Aprendizagem de Máquina é ser capaz de estimar a quantidade de unidades a serem reparadas a partir da duração da chamada telefônica. A Figura 5 mostra o gráfico de dispersão para os dados coletados, onde é possível verificar uma linearidade entre as duas variáveis.

Tabela 1 – Exemplo de um problema de regressão, onde cada registro contém a duração da chamada (minutos) e a quantidade de equipamentos reparados (unidades)

#	Minutos	Unidades	#	Minutos	Unidades
1	23	1	8	97	6
2	29	2	9	109	7
3	49	3	10	119	8
4	64	4	11	149	9
5	74	4	12	145	9
6	87	5	13	154	10
7	96	6	14	166	10

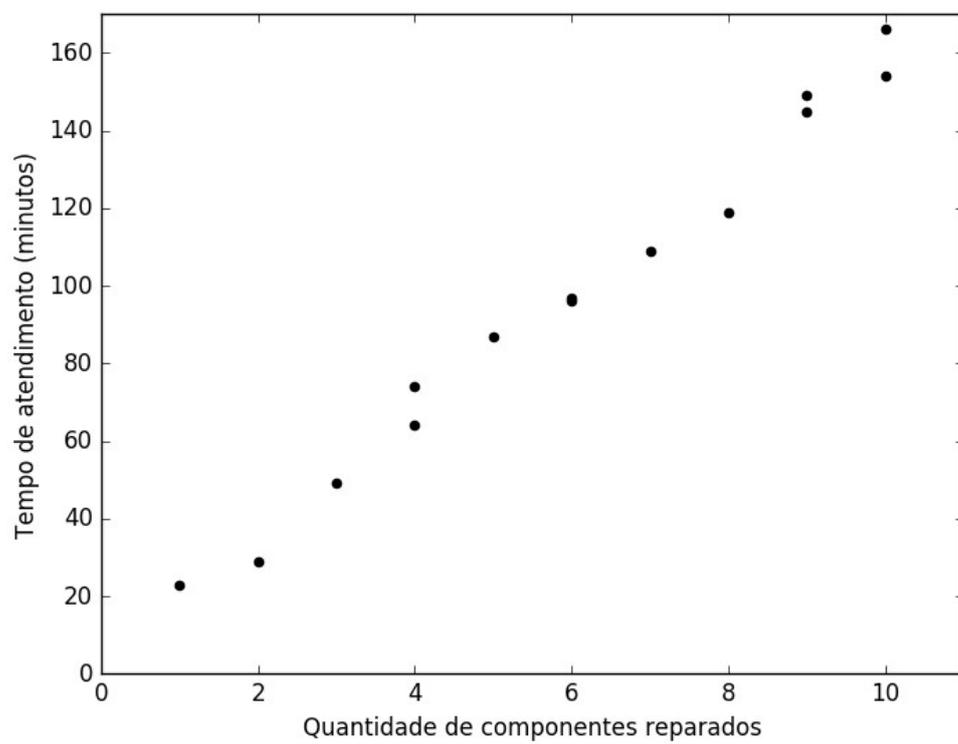


Figura 5 – Gráfico de dispersão contendo a função de regressão linear. Adaptado de (CHATTERJEE; HADI, 2006)

Para confirmar a relação linear entre duas variáveis X e Y , define-se a correlação $Cor(X,Y)$, dada pela expressão

$$Cor(X,Y) = \frac{\sum_{i=1}^n (y_i - \bar{y})(x_i - \bar{x})}{\sqrt{\sum_{i=1}^n (y_i - \bar{y})^2 (x_i - \bar{x})^2}},$$

em que \bar{y} e \bar{x} representam as médias das variáveis y e x , respectivamente. Para o problema de regressão descrito anteriormente, foi obtida uma correlação de 0,996 entre as variáveis envolvidas, indicando a possibilidade de os dados serem modelados por um modelo de regressão linear, já que o valor é próximo de 1,0. A Figura 6 mostra a função que modela os dados e estima a quantidade de unidades a serem reparadas a partir da duração das chamadas de atendimento.

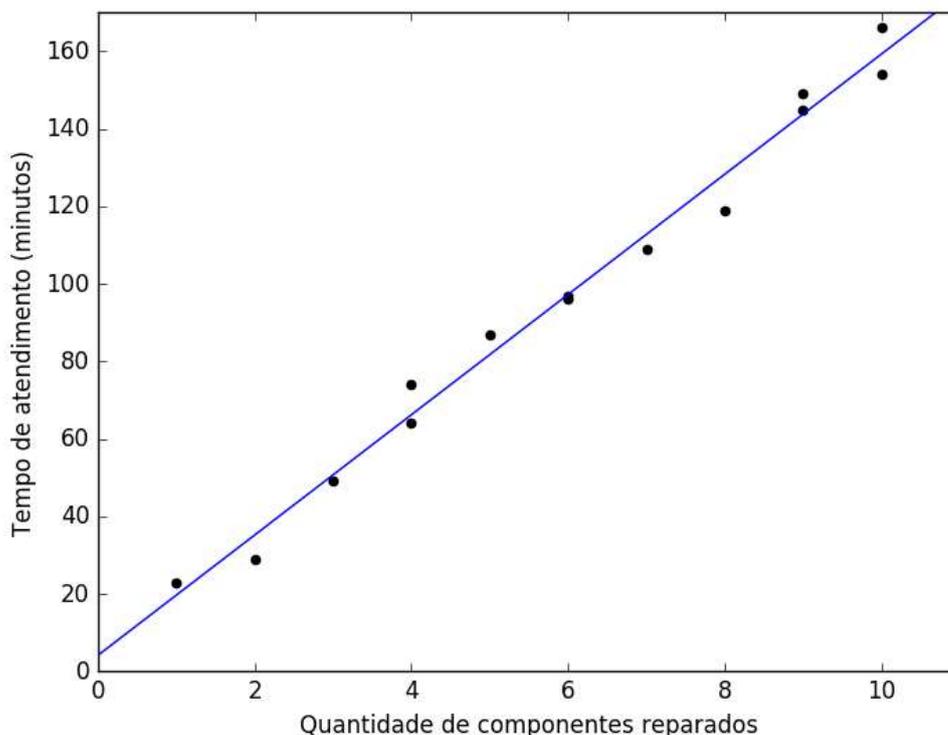


Figura 6 – Gráfico de dispersão contendo a função de regressão linear. Adaptado de (CHATTERJEE; HADI, 2006)

2.3 Avaliação de Modelos

O treinamento de um modelo se baseia em melhorar o desempenho deste modelo em um conjunto de dados. Entretanto, existem cenários onde o treinamento não é capaz de gerar modelos adequados, capazes de classificar amostras desconhecidas. O primeiro cenário é quando o modelo cria regras específicas para cada amostra, perdendo a capacidade de generalização. O segundo cenário é representado pela

situação na qual o modelo não é capaz de aprender o necessário sobre os dados de treinamento e sobre o problema modelado por estes. Dessa forma, para um dado problema, um modelo adequado é aquele capaz de generalizar os dados de treinamento para conseguir classificar novas amostras. Conseqüentemente, avaliar o desempenho de um modelo é análogo a verificar sua capacidade de generalização.

Um método de avaliação amplamente utilizado na literatura é a validação cruzada (*cross-validation*). Este método tem por objetivo estimar a capacidade de generalização de um modelo preditivo, dividindo o conjunto de dados em conjunto de treinamento, conjunto de validação e conjunto de testes, todos mutuamente exclusivos. Quando o modelo a ser testado não necessita de amostras de validação, essas amostras são realocadas para o conjunto de treinamento e o conjunto de testes.

Como a divisão dos dados pode ser feita em diferentes proporções, existem várias possibilidades para a validação cruzada, mas existem três comumente aplicadas, quais sejam, método *holdout*, método *k-fold* e método *leave-one-out*. O método *holdout* consiste em dividir o conjunto de dados em dois subconjuntos mutuamente exclusivos, geralmente em quantidades iguais ou ainda, 2/3 para treinamento e 1/3 para testes. O método *k-fold* possui um parâmetro k que determina a quantidade de subconjuntos que serão originados a partir do conjunto de dados. Os k subconjuntos são mutuamente exclusivos e possuem o mesmo tamanho. A avaliação no método *k-fold* é realizada utilizando-se um subconjunto por vez como o conjunto de testes, enquanto todos os $(k-1)$ restantes são utilizados como conjunto de treinamento. Já o método *leave-one-out* é um caso específico do método *k-fold*, em que a quantidade de subconjuntos é igual ao tamanho do conjunto de dados, ou seja, cada subconjunto contém apenas uma amostra.

A utilização da validação cruzada ajuda a avaliar dois problemas recorrentes no treinamento de modelos: o problema de *overfitting*, onde o modelo se torna específico demais para o conjunto de treinamento utilizado e perde sua capacidade de generalização, e o problema de *underfitting*, onde o modelo não consegue aprender o suficiente sobre problema, sendo irrelevante como um classificador ou regressor. A necessidade de avaliar modelos para cada problema isoladamente se deve ao fato de não existir um modelo que seja o melhor para qualquer que seja o problema. Esta afirmação pode ser vista como uma interpretação do *No Free Lunch Theorem* e foi comprovada pela primeira vez por (WOLPERT; MACREADY, 1997), tendo um papel importante em Aprendizagem de Máquina. Em relação ao desempenho de generalização dos modelos, o teorema indica que não há nenhuma razão que não seja relativa ao contexto e ao problema que favoreça um ou outro conjunto de algoritmos de aprendizagem. Isto significa que cada conjunto de algoritmos apresenta vantagens e desvantagens a depender do problema a ser resolvido. Segundo (DUDA; HART; STORK, 2000), é a apreciação do teorema que nos faz priorizar aspectos que realmente importam sobre o problema --- informações *a priori*, distribuição dos dados, quantidade de dados de treinamento e funções de custo ou recompensa.

O método de avaliação escolhido para este trabalho foi a validação cruzada *k-fold* (KUHNS; JOHNSON, 2013), mostrado no Algoritmo 1. Entretanto, como o foco da dissertação é em problemas de regressão, é necessário selecionar métricas de avaliação para modelos de regressão. Diferentemente de problemas de classificação, em que um acerto é considerado quando a resposta do classificador é idêntica à resposta esperada, problemas de regressão geralmente possuem um erro associado à resposta do regressor. Por exemplo, se a resposta esperada vale 3,0 e a resposta do

regressor é 2,9, temos um erro de 0,1 que pode ser alto ou baixo dependendo do problema avaliado.

Algoritmo 1: Descrição da técnica de validação cruzada <i>k-fold</i> .	
1	Particione os dados randomicamente em k conjuntos mutuamente exclusivos $\{Z_m\}_{m=1}^k$;
2	para $m = 1$ até k faça
3	Use Z_m para validação e os conjuntos restantes $\{Z_j\}_{j=1, j \neq m}^k$ para treinamento;
4	Aplique o método no conjunto de validação Z_m ;
5	fim
6	Retorne as métricas para cada dado de validação testado;

Dessa forma, para avaliar os modelos de regressão, serão consideradas as seguintes métricas durante a realização da validação cruzada *k-fold*:

- Erro Médio Absoluto (EMA)
- Erro Médio Quadrático (EMQ)
- Erro Mediano Absoluto (EMnA)
- Escore R^2

O EMA pode ser definido como

$$EMA = \frac{1}{n} \sum_{i=1}^n |e_i - y_i|,$$

em que e_i e y_i são as respostas esperada e dada pelos modelos, respectivamente, para a i -ésima amostra. O EMA possui certa robustez em relação à presença de *outliers*, pois todos os valores são considerados na computação do erro. Entretanto, todos os valores não são considerados igualmente, diferentemente do que ocorre com o EMQ.

O EMQ, definido como

$$EMQ = \frac{1}{n} \sum_{i=1}^n (e_i - y_i)^2,$$

não apresenta a mesma robustez em relação à presença de *outliers*. Este comportamento se deve ao fato de os valores de erro ($e_i - y_i$) contidos no intervalo $[0,1]$ terem uma contribuição muito menor que os valores de erro contidos no intervalo $(1,\infty)$. Este comportamento, entretanto, ajuda a identificar as ocorrências de *outliers*.

Sob a condição de a quantidade de *outliers* ser pequena, o EMnA, definido como

$$EMnA = \text{mediana}(|e_1 - y_1|, \dots, |e_i - y_i|, \dots, |e_n - y_n|),$$

em que $\text{mediana}(\cdot)$ é a mediana dos valores de erro, é a métrica mais robusta. Isto se deve ao fato de a mediana desconsiderar as caudas da distribuição dos dados. A

utilização destas três métricas de erros é importante, pois cada uma avalia os resultados de modo distinto, ainda que comparáveis, e ajuda a entender os dados.

Por fim, o escore R^2 (também chamado de coeficiente de determinação) é uma métrica que indica a proporção da variância da variável dependente que pode ser estimada pelas variáveis independentes. Seu valor é calculado a partir da soma dos quadrados dos resíduos (SQ_{res}) e da soma dos quadrados totais (SQ_{tot}), dados por

$$SQ_{res} = \sum_{i=1}^n (e_i - y_i)^2$$

e

$$SQ_{tot} = \sum_{i=1}^n (e_i - \bar{e})^2,$$

em que \bar{e} é a média das respostas esperadas. O valor do escore R^2 é então definido como

$$R^2 = 1 - \frac{SQ_{res}}{SQ_{tot}}$$

de forma que o melhor valor é a unidade. Note que também é possível que o valor do escore R^2 seja negativo, o que implica que o modelo não é uma aproximação adequada dos dados.

2.4 Modelos de Regressão

Nesta seção, iremos apresentar brevemente como se dá o treinamento de um regressor e os modelos de regressão utilizados neste trabalho. A escolha dos modelos foi feita de forma que a maior gama de abordagens fosse utilizada, isto é, modelos para dados esparsos ou não, modelos para dados de alta dimensionalidade ou não, entre outros. A justificativa para o não detalhamento dos modelos estudados se dá pelo fato de que são modelos amplamente conhecidos na literatura e possuem aplicações em diversas áreas. Todos os modelos selecionados foram obtidos a partir de (PEDREGOSA, 2011).

Como citado anteriormente, para treinar um modelo, são necessários dados de treinamento contendo as variáveis dependentes e a variável de resposta. Além da base de dados de treinamento, um algoritmo de Aprendizagem de Máquina, tal como *Random Forest* ou *Multi-layer Perceptron* (MLP), deve ser escolhido para ser aplicado aos dados. O modelo final é o resultado do algoritmo de treinamento, de forma que ele pode ser utilizado para estimar novas situações no mesmo contexto. Este processo está descrito na Figura 7. No contexto deste trabalho, os dados de treinamento são informações do *smartphone* e serão detalhados na Seção 3.

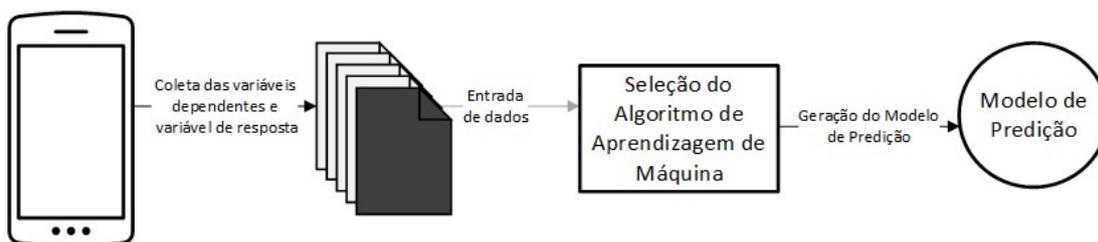


Figura 7 – Processo de treinamento de um regressor

A seguir, iremos descrever sucintamente cada tipo de modelo que foi investigado. Em alguns casos, iremos manter a denominação de um determinado modelo em inglês por não haver uma tradução habitual para a língua portuguesa.

2.4.1 Regressão Linear

Existem diversas técnicas relativas a esta categoria de modelos de regressão. Foram escolhidas três delas para serem utilizadas, quais sejam, as técnicas *Ordinary Least Squares* (OLS), *Lasso Regressor* e *Least Angle Regressor* (LARS) (HASTIE; TIBSHIRANI; WAINWRIGHT, 2015).

A técnica OLS é a técnica de regressão linear mais simples, em que um conjunto de coeficientes é aplicado para melhor aproximar o modelo linear dos dados e minimizar a soma do quadrado dos resíduos, definida na Subseção 2.5. No caso da técnica Lasso, este é um modelo linear que estima coeficientes esparsos e é comumente utilizada em problemas de redução de dimensionalidade, diminuindo o número de variáveis do qual o problema é dependente.

A técnica LARS é um algoritmo de regressão para dados de alta dimensionalidade. É um algoritmo rápido e de baixa complexidade, pontos interessantes relacionados ao processamento de informações de dispositivos móveis, uma vez que algoritmos de complexidade mais alta tendem a necessitar de mais tempo de CPU, resultando em aumento do consumo de energia. Além disso, o algoritmo é capaz de tratar colinearidade entre variáveis.

2.4.2 Regressão usando Máquina de Vetor de Suporte

A utilização de máquinas de vetor de suporte em problemas de regressão é conhecida por técnica *Support Vector Regressor* (SVR) (SMOLA; SCHÖLKOPF, 2004). Atualmente, a técnica SVR é considerada o estado-da-arte para regressão. Sua principal vantagem é a efetividade em espaços de grande dimensionalidade, isto é, em problemas com grande quantidade de características. Outra vantagem é a sua versatilidade, em virtude de permitir a variação do Kernel utilizado, e, por fim, a otimização de memória, devido ao fato de utilizar somente um subconjunto de pontos de treinamento. Otimização de memória é um aspecto importante quando lidamos com dispositivos móveis, visto que acessos de memória também contribuem para o aumento do consumo de energia (CARROLL; HEISER, 2010).

2.4.3 Random Forest

A técnica *Random Forest* foi proposta como um tipo de combinação de classificadores (*ensemble methods*) que emprega Árvores de Decisão (*Classification and Regression Tree*) como classificador base (BREIMAN, 2001). A ideia básica do uso de combinação de classificadores é formar um conjunto de classificadores diversos, onde cada classificador possa se especializar em uma determinada região de decisão, de forma que, por uma regra de decisão escolhida (e.g. voto majoritário), o conjunto tenha desempenho melhor que o classificador base individual.

Para gerar classificadores diversos, a técnica *Random Forest* aplica o *random subspace method* (KUNCHEVA, 2004), uma técnica de amostragem em que um

subconjunto de características é escolhido aleatoriamente com reposição até um número M previamente definido. Após a escolha das características de cada uma das N árvores de decisão presentes na técnica *Random Forest*, os classificadores são treinados individualmente e incluídos no conjunto. A decisão final do modelo é definida como o voto majoritário de todos os classificadores que fazem parte do conjunto.

Entretanto, o modelo *Random Forest* pode ser aplicado a regressores também. Quando utilizada como regressor, *Random Forest* cria um conjunto de árvores de decisão, cujas respostas de cada árvore é um valor contínuo. A Figura 8 mostra um exemplo de árvore de decisão para o problema do resgate de pessoas no Titanic, onde o nó final contém a porcentagem, representada na forma decimal, de chance de uma pessoa ser resgatada (regressão) e uma classe (classificação). Outro ajuste no mecanismo da técnica *Random Forest* é a decisão final: como uma decisão por voto majoritário não pode ser aplicada a um espaço contínuo, a resposta final do conjunto passa a ser a média de todas as respostas individuais.

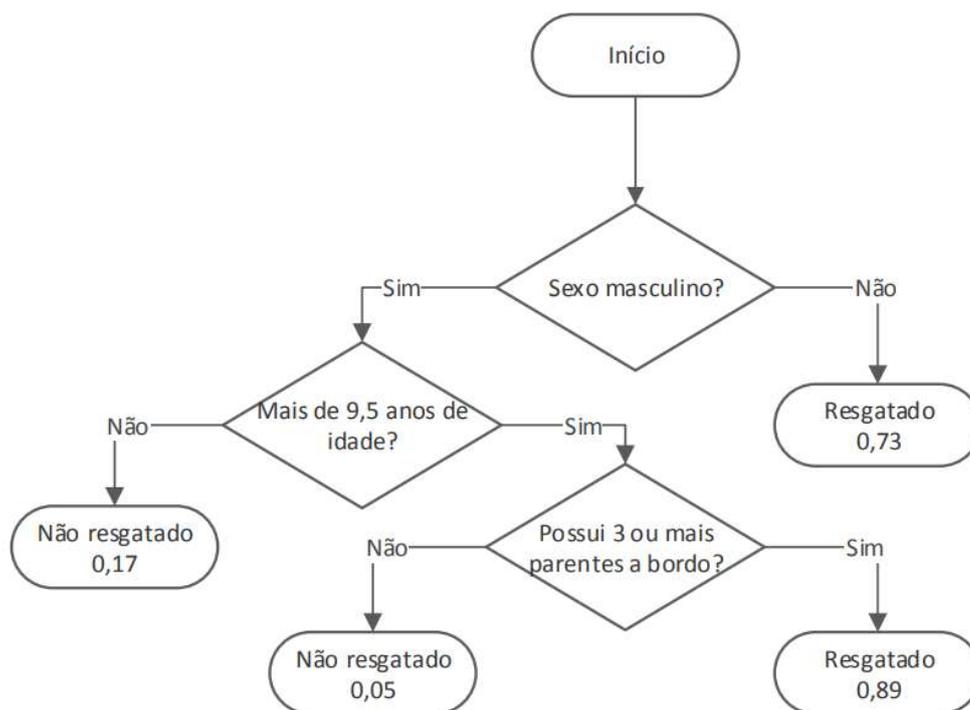


Figura 8 – Exemplo de árvore de decisão como classificador e regressor

Por exemplo, considere um problema em que os dados possuem apenas quatro características (A, B, C e D). Para gerar um modelo *Random Forest* com $N=3$ árvores de decisão, é necessário definir a quantidade de características, M , e selecionar aleatoriamente as características de cada árvore. Tomando $M=4$, a Tabela 2 mostra as características aplicadas a cada árvore. Cada uma das três árvores de decisão do conjunto possui características diferentes e, portanto, tem grande chance de se especializar em regiões de decisão diferentes. Quando uma amostra for aplicada ao

modelo *Random Forest*, ela será aplicada individualmente a cada árvore de decisão do conjunto e a resposta com maior ocorrência será a resposta final do modelo.

Tabela 2 – Exemplo das árvores de decisão de um modelo *Random Forest* ($N=3, M=4$)

#	1	2	3	4
1	A	B	D	A
2	A	C	C	D
3	A	D	B	C

2.4.4 Nearest Neighbors

A categoria de algoritmos *Nearest Neighbors* (NN) é uma das mais simples técnicas de Aprendizagem de Máquina, mas não raramente consegue um desempenho melhor do que outros algoritmos mais elaborados (FERNÁNDEZ-DELGADO, 2014). Trata-se de um método versátil, que utiliza qualquer métrica de distância (comumente é utilizada a distância Euclidiana), e é não-paramétrico, conseguindo prever com sucesso situações onde a linha de decisão é muito irregular. A técnica NN é conhecida como não-generalizante, por não construir um modelo com todo o conjunto de treinamento na comparação. Esta característica torna a complexidade desta técnica bastante variável, uma vez que o crescimento do conjunto de treinamento resulta em aumento de complexidade.

Além da métrica de distância, o outro parâmetro da técnica é a quantidade de vizinhos mais próximos a serem considerados, denotado por K . Em virtude desse parâmetro, o algoritmo é comumente denominado *K-Nearest Neighbors* (KNN). Quando utilizado para classificação, a classe de resposta é aquela de maior ocorrência entre os K vizinhos mais próximos. Para $K=1$, basta tomar a classe do vizinho mais próximo como sendo a resposta. Quando o valor de K é igual à cardinalidade do conjunto de treinamento, a resposta passa a ser a classe de maior ocorrência. Dessa forma, é importante otimizar o parâmetro K de forma a obter o melhor desempenho.

Quando utilizada para regressão, a regra de escolha por voto majoritário não pode ser utilizada. Neste caso, existem duas possibilidades comumente utilizadas: a primeira é o cálculo da média dos K vizinhos mais próximos como a resposta do regressor; a segunda é o cálculo da resposta como uma média do valor de cada um dos K vizinhos mais próximos ponderada pela distância, de forma que os vizinhos tenham mais importância de acordo com a proximidade. Se o cálculo da média for utilizado e se o valor de K for igual à cardinalidade do conjunto de treinamento, todas as respostas serão iguais à média do conjunto.

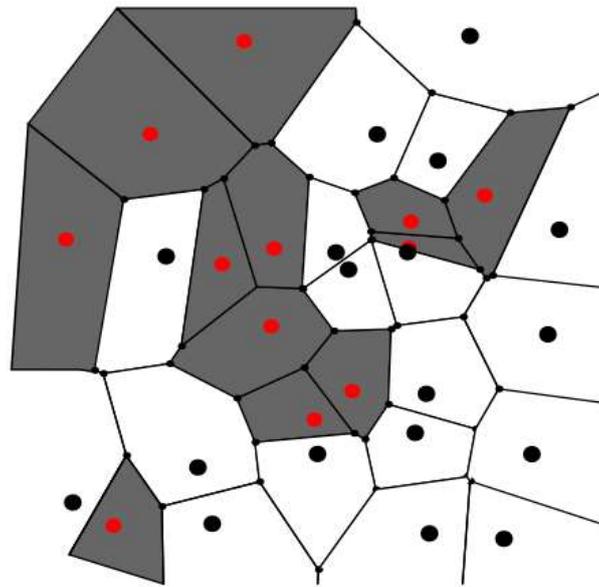


Figura 9 – Regiões de decisão obtidas pela aplicação do algoritmo KNN ($K=1$) em um problema de classificação. As regiões em cinza indicam a classe vermelha, enquanto as regiões em branco indicam a classe preta. Adaptado de (DUDA; HART; STORK, 2000)

A Figura 9 mostra um exemplo de como a técnica KNN ($K=1$) funciona para classificar um conjunto de dados bi-dimensional para duas classes. Note que, como as amostras de treinamento não mudam, é possível visualizar as regiões de cada classe. Se o problema fosse descrito como um problema de regressão, as regiões que determinam classes passariam a determinar os valores de resposta. Em outras palavras, em vez de termos como resposta a classe do vizinho que determina aquela região, a resposta seria o valor deste vizinho.

2.4.5 Regressão por Processo Gaussiano

Segundo (RASMUSSEN; WILLIAMS, 2005), um processo Gaussiano é a generalização de uma distribuição Gaussiana de probabilidade, onde um processo governa as propriedades das distribuições que descrevem as variáveis aleatórias presentes. Dessa forma, uma Regressão por Processo Gaussiano (*Gaussian Process Regression*, GPR) implementa processos Gaussianos para obter o logaritmo da máxima verossimilhança marginal (MVM) durante o treinamento para gerar seu modelo.

Dentre as vantagens da técnica GPR podemos citar o fato de ela interpolar as amostras de treinamento, sua versatilidade (é possível variar os Kernels utilizados) e, por fim, que sua predição é probabilística, sendo capaz de criar camadas de decisão baseado nas probabilidades. Camadas de decisão se referem a identificar uma certa região de interesse e aplicar os dados a um outro classificador ou regressor já treinado e identificado como melhor nesta região. A sua principal desvantagem é a perda de eficiência quando os dados são esparsos, uma vez que a técnica GPR utiliza todos os dados na predição e em espaços de alta dimensionalidade

2.4.6 Multi-layer Perceptron

A técnica MLP faz parte de uma categoria maior de algoritmos de Inteligência Artificial chamada Redes Neurais Artificiais (RNA). As RNA são formadas por um conjunto de unidades básicas de processamento (por exemplo, perceptrons) diferentemente organizadas e com algoritmos de aprendizagem distintos, como mapas de Kohonen ou mapas auto-organizáveis (*Self Organizing Maps*) e redes neurais recorrentes.

A técnica MLP é uma RNA composta por perceptrons com uma camada de entrada, uma camada de saída e, ao menos, uma camada intermediária. Define-se o perceptron como uma unidade que recebe um vetor de valores reais, calcula a combinação linear desses valores e produz como saída 1, se a combinação for maior que um limiar, ou 0, caso contrário (MITCHELL, 1997). Quando utilizado em uma MLP, a saída do perceptron não é comparada a um limiar para discretizar sua resposta (no caso, 0 ou 1), passando o valor computado pela combinação linear como entrada para a camada de perceptrons seguinte.

Outra característica da técnica MLP é conter apenas ligações não-cíclicas, isto é, a informação sempre segue em frente, desde a camada de entrada até a camada de saída. Dessa forma, o treinamento de uma MLP é feito via *backpropagation*, em que os pesos das conexões entre perceptrons são atualizados a partir do erro calculado

durante o treinamento. Inicialmente, todos os pesos são atribuídos de maneira aleatória e, posteriormente, convergem de maneira iterativa.

Como a saída de uma rede neural é uma variável contínua, não é necessário nenhuma modificação para que a MLP seja utilizada como regressor. Sua maior vantagem é a capacidade de aprender modelos não-lineares, entretanto existe uma grande quantidade de hiperparâmetros para ser otimizada (número de camadas intermediárias, número de neurônios nas camadas intermediárias e número máximo de iterações, por exemplo).

3 SELEÇÃO INTELIGENTE DE INTERFACES DE REDE

Fabricantes de hardware e projetistas de software, bem como a comunidade científica, tem investido esforços para buscar soluções que estendam a vida útil da bateria de dispositivos móveis em diferentes níveis, tais como hardware, sistema operacional, tecnologias de transmissão sem fio e aplicações. Em relação às tecnologias de transmissão sem fio, novas alternativas tem surgido com o objetivo de reduzir o custo energético por bit transmitido, como, por exemplo, *Bluetooth Low Energy* (BLE) (BLUETOOTH SIG, 2017) e 6LowPAN (MONTENEGRO, 2007) em redes sem fio de curto alcance. Esta Seção trata da seleção dinâmica de interfaces de rede, no caso redes 3G e Wi-Fi, para dispositivos móveis no intuito de apresentar uma solução para a otimização do consumo de energia e, conseqüentemente, extensão da vida útil da bateria de tais dispositivos. Por questão de limitação da infraestrutura de hardware no momento do desenvolvimento da pesquisa, este trabalho não aborda a utilização da interface de rede 4G. Inicialmente, uma revisão da literatura acerca do tema seleção inteligente de interfaces de rede é abordada. Em seguida, as condições das medições experimentais são apresentadas, com a descrição do *smartphone* utilizado, as características coletadas e as justificativas para as decisões tomadas. Por fim, são apresentados a metodologia empregada e os resultados obtidos sobre como o consumo energético de um *smartphone* seria afetado com a adoção do mecanismo de seleção de interface de rede proposto.

3.1 Introdução

As interfaces de comunicação sem fio são os maiores consumidores de energia em sistemas de computação móvel. Por essa razão, muitos esforços têm sido implementados na tentativa de se propor estratégias de utilização das diversas interfaces de rede presentes nos dispositivos móveis. Em (KELLOKOSKI; KOSKINEN; HAMALAINEN, 2012), a eficiência energética de um dispositivo móvel é analisada, considerando que este está sempre conectado à melhor opção de interface de rede. A análise é justificada no trabalho pela existência de um gasto de energia associado à execução do *handoff*, mecanismo empregado em redes sem fio para lidar com a transição de uma estação móvel de uma célula para outra de maneira transparente ao usuário. Os resultados mostram que apesar de o *handoff* consumir energia, este consumo é viável do ponto de vista energético desde que o novo enlace seja mais eficiente.

Em (DING et al, 2013), é descrito um estudo sobre o impacto que a potência do sinal de RF tem sobre o consumo de energia em *smartphones*. Este trabalho utilizou dados de 3.785 dispositivos móveis e reforça a importância de se escolher bem a interface de rede, pois 43% e 21% dos dados são transmitidos em más condições de 3G e Wi-Fi, respectivamente. Em relação à qualidade dos sinais de RF das interfaces de rede, o trabalho indica que a degradação do sinal pode aumentar o custo energético de uma transferência em até 8 vezes para redes Wi-Fi e até 50% a mais para redes 3G.

(ABBAS et al, 2013) propõe a utilização de uma árvore de decisão para seleção inteligente de interface de rede com o objetivo de entregar a interface com a melhor qualidade de serviço (QoS). Para tal, os autores criam um conjunto de regras que orienta a ramificação da árvore de decisão final gerada a partir dos dados.

Em (ABBAS; SAADE, 2015), os autores utilizam um mecanismo de lógica difusa (*fuzzy logic*) para selecionar a melhor interface com o objetivo de escolher a interface que forneça a melhor qualidade de serviço (QoS). Neste trabalho, são escolhidas variáveis menos subjetivas em relação ao trabalho anterior, de forma que não existe nenhuma entrada dos autores que não sejam exclusivamente os dados. Resultados mostram que o método proposto consegue ser mais eficiente em relação à utilização de banda e consumir menos energia do que ao utilizar apenas umas das interfaces isoladamente.

(PRABHAVATHI; NITHYANANDAN, 2013) descreve o problema de seleção de interfaces como um problema em um ambiente dinâmico, tendo o objetivo de responder a interface com a melhor qualidade de serviço (QoS). Os autores concluem que o algoritmo CODIPAS-RL baseado em Boltzmann-Gibbs é o que possui o melhor desempenho nas simulações executadas.

(LAI; CHAIT; CHEN, 2012) emprega um processo de decisão multicritérios, criando uma função de utilidade conjunta que mistura utilidades aditiva e multiplicativa. Na avaliação do método proposto, os autores propõem a utilização de um conceito de satisfação denominado taxa de usuários satisfeitos (*Satisfied User Ratio*, SUR) e mostram que o método proposto consegue uma taxa maior que um algoritmo baseado em utilidade, especificamente *Net-Utility Algorithm*, executado pelos autores via simulações.

(AWAD; MOHAMED; CHIASSERINI, 2016) também emprega um processo de decisão multicritérios, mas inclui o consumo de energia como um dos critérios a ser otimizado. Resultados de simulações mostram que o método proposto é eficiente comparado a um algoritmo de seleção existente, especificamente E-PoFANS, e também é capaz de se adaptar a diversas condições das redes.

(SONG; JAMALIPOUR, 2005) tem uma abordagem diferente, analisando o problema de seleção inteligente de interfaces de rede utilizando conceitos matemáticos e da teoria da informação com o objetivo de entregar a interface de rede com a melhor qualidade de serviço (QoS). Inicialmente, o método proposto realiza um Processo Analítico de Hierarquias (*Analytic Hierarchy Process*, AHP) e uma Análise Relacional Cinza (*Grey Relational Analysis*, GRA) para decidir os fatores que definem a seleção da interface de rede e para descobrir as relações entre estes fatores, respectivamente. A tomada de decisão é feita comparando as condições atuais, segundo os fatores escolhidos pelo AHP, e as condições ideais, definida pela GRA. Resultados das simulações mostram que o método proposto consegue um bom desempenho, ainda que não seja comparado com nenhum outro método.

Em (HADDAD et al, 2016), os autores propõe a criação de um mecanismo de seleção de interfaces de rede focado na rede, ao invés de estar focado nos dispositivos móveis. O mecanismo proposto também emprega um processo de decisão multicritérios, mas com o objetivo de otimizar o ganho econômico do operador de rede sem afetar o desempenho dos usuários. Resultados mostram que o mecanismo proposto consegue empregar mais usuários na arquitetura de redes sem a necessidade de melhorias na infraestrutura.

(GAO; ZHANG, 2015) é um dos poucos trabalhos onde a economia de energia é descrita como foco principal, isto é, a diminuição do consumo energético pelo *smartphone* é incluído como um dos objetivos da proposta. Neste trabalho, os autores utilizam um algoritmo de ajustes de pesos adaptativos juntamente com um modelo de otimização multiobjetivo para ser mais eficiente energeticamente sem que afete

negativamente a qualidade de serviço (QoS). Resultados das simulações mostram que o método proposto pelos autores consegue ser muito mais eficiente no consumo de energia do que o algoritmo tradicional.

Ainda que um mecanismo de seleção de interface de rede tenha impacto significativo no consumo de energia de um *smartphone*, as pesquisas acerca de tais mecanismos ainda são recentes. Neste âmbito, são minoria os trabalhos que têm foco na diminuição da energia gasta pelo dispositivo móvel. A Tabela 3 sintetiza as contribuições dos trabalhos relacionados citados anteriormente. Dessa forma, este trabalho propõe um mecanismo de seleção de interface de rede focado em diminuir o consumo energético, apresentando um método que utiliza algoritmos de regressão, sem a necessidade de utilização de informações subjetivas (por exemplo, a definição da capacidade da rede em função da localização (ABBAS; SAADE, 2015)).

3.2 Mecanismo Dinâmico Proposto

O objetivo deste trabalho é propor um mecanismo dinâmico de seleção de interface de rede (Wi-Fi ou 3G) utilizando técnicas de Aprendizagem de Máquina focadas em regressão e levando em conta o critério de otimização do custo energético por byte transferido. Aqui, definimos o custo energético por byte transferido como a energia gasta para cada byte transmitido por uma dada interface de rede, de forma que quanto menor o custo energético por byte transferido, maior sua eficiência energética. Para atingir o objetivo proposto, dois regressores são utilizados para estimar as eficiências energéticas de cada interface de rede em um dado instante.

Tabela 3 – Contribuições dos trabalhos relacionados a seleção de interfaces de rede

Artigo	Método	Foco	Objetivo	Dados reais
Mecanismo proposto	Algoritmos de regressão	<i>Smartphone</i>	Economia de energia	Sim
(ABBAS, 2013)	Classificação por árvore de decisão	<i>Smartphone</i>	Qualidade de serviço	Não
(ABBAS, 2015)	Classificação por mecanismo <i>fuzzy</i>	<i>Smartphone</i>	Qualidade de serviço	Não
(PRABHAVATHI, 2013)	Decisão por teoria dos jogos	<i>Smartphone</i>	Qualidade de serviço	Não
(LAI, 2012)	Decisão multi-critérios	<i>Smartphone</i>	Qualidade de serviço	Não
(AWAD, 2016)	Decisão multi-critérios	<i>Smartphone</i>	Qualidade de serviço; economia de energia	Não
(SONG, 2005)	Modelos matemáticos e Teoria da Informação	<i>Smartphone</i>	Qualidade de serviço	Não
(HADDAD, 2016)	Decisão multi-critérios	Infraestrutura de rede	Ganho monetário	Não
(GAO, 2015)	Algoritmo de ajustes de pesos adaptativos	<i>Smartphone</i>	Economia de energia (parcialmente)	Não

A Figura 10 ilustra o funcionamento do mecanismo proposto. A cada instante, características do dispositivo móvel são coletadas e utilizadas como entrada para os modelos de predição das interfaces de rede Wi-Fi e 3G já treinados previamente. A resposta de cada modelo é o custo energético, C_b , estimados. A decisão sobre a interface de rede escolhida é feita comparando os custos energéticos: se o custo energético estimado para a interface de rede Wi-Fi, a interface de rede 3G é ativada; caso contrário, a interface de rede Wi-Fi é ativada.

3.2.1 Medições do smartphone

Para estimar o custo energético por byte transferido de uma interface de rede, foram conduzidas medições do *smartphone* em campo utilizando um aplicativo não-comercial desenvolvido para este trabalho. Em relação à interface de rede Wi-Fi, o ambiente continha 6 pontos de acesso Wi-Fi, embora o dispositivo sob teste só pudesse se conectar a um deles que atingia todo o ambiente de coleta. Assim como a interface de rede Wi-Fi, a interface 3G também foi acessível em todo o ambiente de coleta. As características do *smartphone*, também chamado neste trabalho por dispositivo sob testes, estão apresentadas na Tabela 4. O funcionamento do aplicativo se dá da seguinte maneira: ao ativar a medição, o aplicativo coleta um conjunto de características a cada cinco segundos e as registra em um arquivo. As características coletadas pelo aplicativo estão listadas na Tabela 5. As características marcadas (*) são aquelas utilizadas para calcular o custo energético por byte transferido. Para evitar a influência da queda de tensão da bateria em função da carga remanescente, como descrito em (HOQUE; TARKOMA, 2015), todas as medições foram iniciadas com a bateria em 100% da sua carga total e tiveram duração máxima de 5 minutos, quando a medição era pausada e o dispositivo sob teste recarregado.

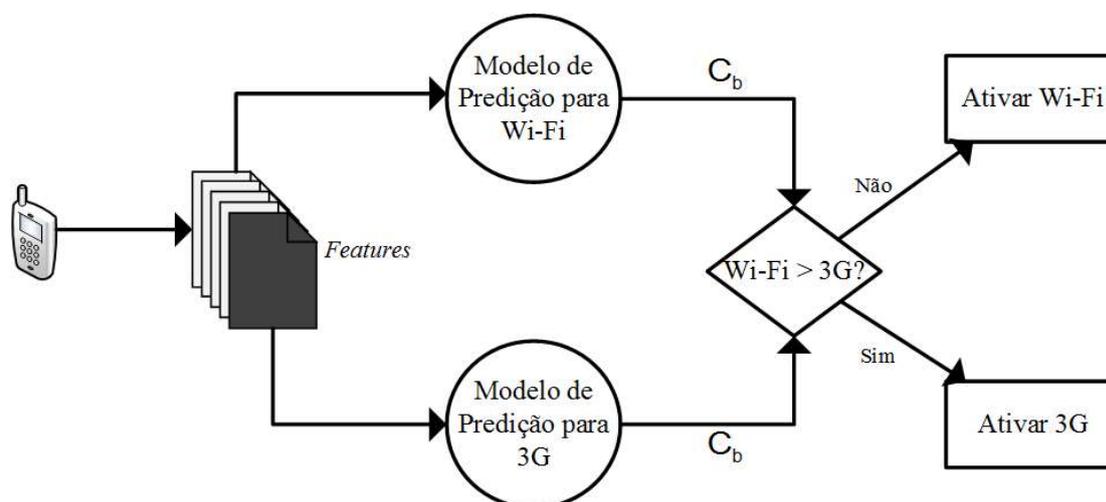


Figura 10 – Mecanismo proposto de seleção dinâmica de interfaces de rede

Tabela 4 – Descrição do dispositivo móvel sob testes

Dispositivo	Motorola Moto G 2ª Geração (XT1068)	
Rede	2G	GSM 850 / 900 / 1800 / 1900 MHz
	3G	UMTS 850 / 900 / 1900 / 2100 MHz
Dados	Velocidade	HSDPA/HSUPA 21,1/5,76 Mbps
	WLAN	Wi-Fi 802.11 b/g/n, Wi-Fi hotspot
Display	Tela	LCD IPS com 16 milhões de cores
	Tamanho	720x1080 pixels, 5 polegadas
Bateria	Capacidade	2070 mAh
Plataforma	SO	Android M (6.0)
	Chipset	Qualcomm Snapdragon MSM8926
	CPU	Quad-core 1,2 GHz
	GPU	Adreno 305

Tabela 5 – Características coletadas pelo uso do aplicativo não-comercial.

Característica	Definição
Informações de bateria*	Tensão e corrente da bateria.
Informações do tempo de execução*	Tempo de execução da coleta.
Informações de transferência de dados*	Quantidade de bytes transferidos.
Configurações globais do <i>smartphone</i>	Conexão ADB habilitada, Bluetooth habilitado.
Configurações do <i>smartphone</i>	Valor do acelerômetro, provedor de localização ativo e modo atual do provedor de localização (se ativo).
Configurações de Bluetooth do <i>smartphone</i>	Estado do Bluetooth e estado de busca do Bluetooth.
Configurações de Wi-Fi do <i>smartphone</i>	Estado do Wi-Fi, potência e frequência do sinal, velocidade de conexão.
Configurações da rede celular do <i>smartphone</i>	Tipo de rede conectada, estado da conexão, tipo de atividade da conexão, potência do sinal.
Informações de processos no <i>smartphone</i>	Lista de processos e porcentagem de consumo de CPU.

Em relação às características utilizadas em trabalhos relacionados, existe uma variedade delas priorizadas entre os autores. Em (ABBAS et al, 2013), o algoritmo proposto considera as seguintes variáveis: disponibilidade das redes, potência do sinal de RF, tamanho do arquivo a ser baixado, nível de bateria, tipo de aplicação (sensível ou não), velocidade e localização do usuário. Em (ABBAS; SAADE, 2015), as variáveis são a potência do sinal de RF de cada rede, a disponibilidade da rede Wi-Fi e a velocidade do usuário. Várias outras propostas também utilizam estas variáveis com algumas pequenas diferenças: (LAI; CHAIT; CHEN, 2012) inclui o custo monetário de se utilizar cada interface; (CHOWDHURY et al, 2009) inclui o custo monetário e a segurança de cada interface de rede, enquanto (GAO; ZHANG, 2015) adiciona a porcentagem de perda de pacotes de cada interface.

Apesar de contribuírem para o consumo de energia do dispositivo, algumas características do *smartphone* não foram coletadas, pois pesquisas mostram não haver impacto destas características no cenário de seleção de interface de rede. Por exemplo, em (LI et al, 2014), é mostrado que o consumo de energia devido ao brilho da tela pode ser modelado como uma função linear, tendo impacto no consumo total de energia do *smartphone*, mas não no consumo de energia relativo a utilização de uma determinada interface de rede. Em relação aos sensores (luminosidade, giroscópio e acelerômetro), a condição é a mesma, pois existe um consumo energético associado, mas que não interfere no cenário de seleção de interface de rede (KOENIG; MEMON; DAVID, 2013).

A medição das condições de cada interface de rede (Wi-Fi e 3G) foi feita via API do Android², já que é possível verificar as condições das redes utilizando a API mencionada. Para medir condições relativas à interface Wi-Fi, foi utilizada a classe WifiManager, enquanto a classe TelephonyManager foi usada para as medições da rede celular.

Para a interface Wi-Fi, foram coletadas informações da potência do sinal (*Received Strength Signal Indicator*, RSSI), o estado da rede Wi-Fi (inativa, ativa, em transição ou desconhecido), a frequência do sinal e a velocidade da transmissão. Para a interface 3G, as medições foram o tipo da rede, a potência do sinal de RF (RSSI), o estado da conexão (conectado, em conexão, desconectado ou suspenso), o estado da atividade de dados (dormiente, recebendo dados, enviando dados, recebendo e enviando dados ou sem tráfego) e o estado de chamadas (em chamada, tocando ou sem atividade).

Em relação às medições de bateria, existem diversos equipamentos (*hardware*) externos ao *smartphone* voltados para a medição de parâmetros de baterias, tais como tensão e corrente elétrica. Ainda que estes tenham a seu favor o fato de não possuírem erros de medição associados, a limitação de mobilidade, devido ao seu tamanho, dificulta a utilização destes equipamentos em testes de campo. Outro fator que atrapalha a utilização desses equipamentos são seus preços: o Power Monitor, um equipamento da Monsoon Solutions Inc. para medição de tensão e corrente elétrica da bateria de *smartphones*, custa em torno de \$771,00³.

Entretanto, segundo (BORNHOLT; MYTROWICZ; MCKINLEY, 2012), processadores de *smartphones* modernos proveem uma leitura confiável das medições de parâmetros da bateria. Testes realizados pelo autor mostram que existe um erro de apenas $2\% \pm 0,02\%$ em relação às medições fornecidas pelo Power Monitor. Esta

² <https://developer.android.com/guide/index.html>

³ Valor conferido em Novembro/2016 em <https://www.monsoon.com/LabEquipment/PowerMonitor/>

evolução dos componentes por parte dos fabricantes também tem trazido uma gama de aplicativos capazes de avaliar a carga de utilização do *smartphone*, incluindo informações relativas à bateria, como é o caso do Treprn Profiler⁴, aplicativo desenvolvido pela fabricante de chips Qualcomm.

Dessa forma, foram utilizados meios via software para coletar informações relativas à bateria utilizadas pelo *smartphone*. Para a coleta do valor de tensão da bateria em milivolts (mV), foi utilizada a classe BatteryManager, disponível na API do Android. Apesar de o valor de corrente elétrica da bateria não estar disponibilizada na API do Android, o dispositivo em teste disponibiliza o valor da corrente elétrica em microampères (μA) em seus arquivos do sistema (sob o caminho *sys/class/power_supply/bms/current_now*). A partir das informações do *smartphone* coletadas, foram testados os modelos de regressão listados na Seção 2.4 e selecionado o de desempenho para cada interface de rede. Note que é possível que o modelo selecionado para estimar o custo energético por byte transferido da interface de rede Wi-Fi seja diferente do modelo escolhido para estimar o custo energético por byte transferido da interface de rede 3G.

Baseado nas medições de tensão e corrente instantâneas, definimos a potência instantânea P_i (dada em nW) como

$$P_i = V_i \cdot I_i$$

em que V_i é a tensão da bateria, dada em mV , e I_i é a corrente elétrica instantânea, dada em μA . A partir do valor de P_i , podemos calcular a energia consumida E_c , tal que

$$E_c = P_i \cdot \Delta t$$

em que Δt é o intervalo de tempo (em s) no qual a potência é consumida.

Face ao descrito, o custo energético por byte transferido, denotado por C_b , é definido como

$$C_b = E_c / Q_b$$

em que E_c é a energia consumida (em nJ) no intervalo de tempo Δt e Q_b é quantidade de bytes transferidos no mesmo intervalo de tempo Δt . Por questões de simplificação, o custo energético por byte transferido será denominado apenas de custo energético deste ponto em diante. Dessa forma, valores pequenos de custo energético indicam melhor utilização da carga da bateria, já que menos energia foi gasta para cada byte transferido.

3.2.2 Metodologia Empregada

Como apresentado anteriormente, a abordagem adotada para a seleção de interface de rede é a de estimar o custo energético de cada interface de rede disponível e selecionar aquela apresentar o melhor desempenho, ou seja, a solução de maior eficiência energética. Dessa forma, cada passo da metodologia descrita a seguir foi aplicado a cada uma das interfaces de rede (Wi-Fi e 3G).

1. Coleta de dados separadamente em diferentes condições de rede para diferentes atividades, isto é, para cada atividade, garantir a variação da

⁴ <https://play.google.com/store/apps/details?id=com.quicinc.treprn&hl=pt-br>

- potência do sinal de RF para cada interface de rede. As atividades consideradas são:
- a. *Download* de arquivos durante 10 minutos: A escolha desta atividade tem o propósito de prover um cenário de tráfego TCP.
 - b. *Streaming* de vídeo em qualidade HD (720p) com volume a 50% e brilho de tela em 10%: A escolha desta atividade tem o propósito de prover um cenário de tráfego UDP.
2. Avaliação dos dados coletados por meio de um algoritmo de seleção de características com o intuito de verificar quais delas são relevantes para estimar o consumo energético do dispositivo sob teste. Este passo tem por objetivo descartar características irrelevantes e simplificar o modelo de regressão final.
 3. Teste dos modelos descritos na Seção 2.4 para cada conjunto de dados de atividades coletados para cada interface de rede individualmente. Este passo tem por objetivo avaliar os modelos capazes de estimar corretamente os valores de custo energético para cada atividade listada no passo 1.
 4. Escolha do melhor modelo baseado nos critérios descritos na Seção 2.3.
 5. Execução de simulação para verificar o ganho energético ao se utilizar o mecanismo de seleção inteligente de interface de rede proposto.

É importante ressaltar que a escolha das atividades (listadas no passo 1) não contemplou aquelas com baixo tráfego de dados, como, por exemplo, *web-browsing*. A justificativa para isso é o fato de que a variação da taxa de transferência de dados inviabiliza uma estimativa correta do custo energético para uma determinada interface de rede. Em outras palavras, a quantidade de bytes transferidos em um intervalo de tempo pode não ser influenciado pelas condições da rede. Esta situação, portanto, pode gerar uma estimativa incorreta pelos regressores, afetando o desempenho do mecanismo de seleção de interface de rede proposto.

3.2.3 Resultados Numéricos

Como o objeto de estudo é a seleção inteligente das interfaces de rede Wi-Fi e 3G, inicialmente foi realizada uma análise dos dados coletados a fim de garantir que estes sejam capazes de representar as diferentes condições de rede sob as quais um *smartphone* possa ser operar. Os resultados mostrados nas Tabelas 5 e 6 foram agrupados pela interface de rede utilizada, mantendo ambas as atividades para cada uma.

A Tabela 5 mostra que os valores da potência do sinal de Wi-Fi (característica Wi-Fi RSSI) variam de -80 dBm a -27 dBm. Segundo (ABBAS; SAADE, 2015), este intervalo abrange valores de potência que caracterizam o sinal como muito fraco, fraco, médio, forte e muito forte, atingindo assim o objetivo da coleta de dados. Para o caso dos valores de potência do sinal de 3G (característica 3G RSSI na Tabela 6), o intervalo de valores é de -93 dBm a -67 dBm, também seguindo as condições utilizadas em (ABBAS; SAADE, 2015) para caracterizar o sinal como muito fraco, fraco, médio, forte e muito forte, como mostrado na Tabela 6. A Tabela 7 mostra os valores utilizados para caracterizar o sinal a partir de sua potência de RF.

Pelos dados apresentados nas Tabelas 5 e 6, é perceptível que, considerando a média dos dados coletados, a utilização da interface de rede 3G consome mais energia que a interface de rede Wi-Fi, se observada de forma isolada, confirmando os resultados de (DING et al, 2013). Entretanto, se levado em consideração o custo energético, existem condições de rede que favorecem a utilização da interface 3G sobre a interface Wi-Fi.

Como as características são abrangentes, é possível que algumas delas não tenham impacto na seleção da interface de rede a ser utilizada. Para determinar aquelas que impactam na seleção da interface de rede com maior eficiência energética, foi aplicado um algoritmo de redução recursiva de características (*Recursive Features Elimination*, RFE) (GUYON et al, 2002). A Tabela 8 mostra o resultado obtido com a aplicação do algoritmo RFE, isto é, o *ranking* de importância de cada característica em relação à variável de resposta (eficiência energética). As características relativas à bateria não estão presentes na Tabela 8 devido à queda de tensão citada anteriormente, de forma que estas características não são utilizadas para estimar a eficiência energética. A exclusão das características se dá pelo fato de os modelos não serem treinados com valores baixos de tensão, de forma que a utilização de tais características poderia piorar o desempenho dos regressores.

Tabela 6 – Análise de características relativas à utilização da interface de rede Wi-Fi

Característica	Média	Valor mínimo	Valor máximo	Mediana
Wi-Fi RSSI	-58,55 dBm	-80 dBm	-27 dBm	-59 dBm
Uso de CPU pelo usuário	21,30%	2,00%	41,00%	20,00%
Uso de CPU pelo sistema	12,20%	5,00%	22,00%	12,00%
Corrente da bateria	337,46 mA	205,98 mA	483,78 mA	341,26 mA
Tensão da bateria	4,20 V	4,17 V	4,24 V	4,19 V

Tabela 7 – Análise de características relativas à utilização da interface de rede 3G

Característica	Média	Valor mínimo	Valor máximo	Mediana
3G RSSI	-74,11 dBm	-103 dBm	-53 dBm	-73 dBm
Uso de CPU pelo usuário	20,61%	6,00%	35,00%	20,00%
Uso de CPU pelo sistema	11,56%	6,00%	20,00%	11,00%
Corrente da bateria	425,57 mA	326,14 mA	770,16 mA	408,84 mA
Tensão da bateria	4,20 V	4,17 V	4,20 V	4,22 V

Tabela 8 – Intervalos de caracterização de potência de sinal de RF (em dBm)

Interface de rede	Muito fraco	Fraco	Médio	Forte	Muito forte
Wi-Fi	$(-\infty, -85)$	$[-85, -75)$	$[-75, -65)$	$[-65, -55)$	$[-55, \infty)$
3G	$(-\infty, -95)$	$[-95, -85)$	$[-85, -75)$	$[-75, -65)$	$[-65, \infty)$

A partir do resultado obtido pelo algoritmo RFE, algumas características foram descartadas para diminuir o tempo de treinamento dos modelos e a quantidade de dados necessária. O *ranking* de corte foi escolhido como aquele em que não há perda de desempenho e o número de características descartadas foi o maior possível. Dessa forma, o *ranking* de corte foi estabelecido em 12.

Tabela 9 – Características coletadas e *ranking* gerado pelo algoritmo RFE

Característica	Ranking
Porcentagem de uso de CPU pelo usuário	1
Potência do sinal da rede celular	2
Velocidade da conexão do Wi-Fi	3
Potência do sinal do Wi-Fi	4
Porcentagem de uso de CPU pelo sistema	5
Quantidade de bytes transferidos	6
Frequência do sinal do Wi-Fi	7
Tipo de atividade de dados na conexão	8
Estado de ligação da rede celular	9
Estado da conexão de dados da rede celular	10
Tipo de conexão de dados da rede celular	11
Estado do Wi-Fi	12
Estado do Bluetooth	13
Estado de busca do Bluetooth	14
Bluetooth habilitado	15
Provedor de localização ativo	16
Modo atual do provedor de localização (se ativo)	17
Valor do acelerômetro	18
Conexão ADB habilitada	19

Uma vez realizada a análise dos dados coletados e a redução de características por meio do algoritmo RFE, a próxima etapa na obtenção de resultados consiste na avaliação dos modelos, conforme descrição feita na Seção 2.3. Para se adequar melhor aos modelos avaliados, o custo energético foi escalado em 10^6 para que seus valores

ficassem situados na faixa da dezena. A fim de se analisar o desempenho de cada modelo, foram realizadas avaliações para cada atividade (listada no passo 1 da metodologia), considerando cada interface de rede isoladamente e as métricas listadas na Seção 2.3.

As Tabelas 9 e 10 mostram os resultados para as atividades de *download* e *streaming*, respectivamente, utilizando a interface de rede Wi-Fi. Os parâmetros para os três melhores modelos utilizados para cada atividade desta interface de rede estão listados no Apêndice A. Os resultados obtidos foram distintos para cada atividade. Para a atividade de *download*, houve três modelos que se destacaram (*K-NN*, *Random Forest* e *MLP*), conseguindo um bom desempenho quando treinados e aplicados na mesma atividade. Já para a atividade de *streaming*, somente um modelo (*MLP*) conseguiu resultados razoáveis, pois tem um escore R^2 bom, mesmo com medidas de erro altas. Uma possível explicação para tal resultado está no fato de a atividade de *streaming* possuir a peculiaridade de ter variações na quantidade de bytes transferidos, o que faz com que nem sempre a maior taxa de transferência de dados seja utilizada, afetando assim o cálculo do custo energético. Por outro lado, a atividade de *download* tende a utilizar a maior taxa de transferência de dados disponível, refletindo as condições de rede de forma mais confiável e, conseqüentemente, permitindo o cálculo correto do custo energético.

Tabela 10 – Desempenho dos regressores para *download* em rede Wi-Fi

Regressor	<i>EMA</i>	<i>EMQ</i>	<i>EMnA</i>	R^2
OLS	241,48	$1,59 \cdot 10^5$	170,09	0,4138
Lasso	231,02	$1,59 \cdot 10^5$	128,88	0,4289
LARS	219,88	$1,50 \cdot 10^5$	127,88	0,4482
SVR	294,64	$3,10 \cdot 10^5$	145,17	-0,0757
<i>Random Forest</i>	58,31	$2,76 \cdot 10^4$	2,62	0,8861
<i>K-NN</i>	61,10	$3,85 \cdot 10^4$	2,25	0,8925
GPR	329,12	$2,97 \cdot 10^6$	212,96	-0,0769
MLP	98,96	$4,85 \cdot 10^4$	22,73	0,8256

Tabela 11 – Desempenho dos regressores para *streaming* em rede Wi-Fi

Regressor	EMA	EMQ	EMnA	R ²
OLS	$9,03 \cdot 10^4$	$2,53 \cdot 10^{10}$	$5,95 \cdot 10^4$	-38,0253
Lasso	$7,41 \cdot 10^4$	$2,23 \cdot 10^{10}$	$4,10 \cdot 10^4$	-17,8862
LARS	$4,11 \cdot 10^4$	$2,29 \cdot 10^{10}$	286,44	-0,1188
SVR	$4,19 \cdot 10^4$	$2,28 \cdot 10^{10}$	$1,60 \cdot 10^3$	-0,0790
<i>Random Forest</i>	$3,64 \cdot 10^4$	$1,02 \cdot 10^{10}$	182,02	0,6645
K-NN	$3,19 \cdot 10^4$	$1,21 \cdot 10^{10}$	50,09	-1,1190
GPR	$4,12 \cdot 10^4$	$2,29 \cdot 10^{10}$	362,18	-0,1281
MLP	$2,33 \cdot 10^4$	$5,61 \cdot 10^9$	$1,97 \cdot 10^4$	0,8283

Dessa forma, a atividade de *download* foi escolhida para definir qual a melhor interface de rede a ser utilizada com foco no custo energético. Para decidir qual dos três modelos é o melhor estimador do custo energético para a interface de rede Wi-Fi, foi realizada uma análise comparativa das ordens de grandeza do custo energético real e daquele estimado pelos modelos de regressão e os resultados mostrados na Tabela 11. A intenção dessa comparação é auxiliar a avaliação dos desempenhos dos regressores, devido à proximidade das métricas analisadas. Para o modelo *Random Forest*, 82,4% das respostas do modelo têm a mesma ordem de grandeza das respostas esperadas, enquanto K-NN e MLP possuem apenas 80,9% e 73,5%, respectivamente. Com base nas medidas de erro apresentadas na Tabela 9 e nos resultados apresentados na Tabela 11, o melhor regressor para estimar o custo energético da interface de rede Wi-Fi para a atividade de *download* foi o *Random Forest*, pois foi a técnica que obteve o menor erro.

Tabela 12 – Comparação das ordens de grandeza dos custos energéticos real e estimado pelos regressores para a interface de rede Wi-Fi (atividade de *download*)

Regressor	Ordem de grandeza (%)		
	Igual	Maior	Menor
<i>Random Forest</i>	82,4%	8,8%	8,8%
K-NN	80,9%	8,8%	10,3%
MLP	73,5%	14,7%	11,8%

Em relação à avaliação da interface de rede 3G, algumas características utilizadas durante a avaliação da interface de rede Wi-Fi não podem ser utilizadas. Isto porque, em um cenário de utilização real, a seleção de interface de rede nativa (*hardcoded*) do sistema operacional Android sempre utiliza a interface Wi-Fi, impossibilitando a coleta da quantidade de bytes transferidos pela interface 3G. Além da quantidade de

bytes transferidos, as informações sobre a condição da rede Wi-Fi também são ignoradas para estimar o custo energético da rede 3G.

Para viabilizar o treinamento dos modelos de regressão para a interface 3G, a interface de rede Wi-Fi é desligada durante a coleta de dados de treinamento e somente a interface 3G fica ativa. Dessa forma, os modelos treinados para estimar o custo energético da interface 3G não possuem como característica a quantidade de bytes transferidos. Entretanto, assim como acontece com as informações de bateria que são apenas utilizadas para calcular o custo energético que é utilizada no treinamento dos modelos, a informação sobre a quantidade de bytes transferidos é computada no cálculo do custo energético.

As Tabelas 12 e 13 mostram os resultados para as atividades de *download* e *streaming*, respectivamente, utilizando a interface de rede 3G. Os parâmetros para os três melhores modelos utilizados para cada atividade desta interface de rede estão listados no Apêndice A.

Assim como os resultados da interface de rede Wi-Fi, as duas atividades tiveram resultados diferentes. Enquanto os modelos de regressão *Random Forest*, *K-NN* e *MLP* tiveram medidas de erros baixas para a atividade de *download*, nenhum modelo obteve desempenho aceitável para a atividade de *streaming*.

Tabela 13 – Desempenho dos regressores para *download* em rede 3G

Regressor	<i>EMA</i>	<i>EMQ</i>	<i>EMnA</i>	R^2
OLS	19,31	863,69	14,31	0,0874
Lasso	16,96	931,44	12,00	0,2967
LARS	17,22	924,41	11,78	0,2927
SVR	19,47	$1,32 \cdot 10^3$	10,71	-0,0527
<i>Random Forest</i>	14,56	693,24	9,03	0,4654
<i>K-NN</i>	14,64	916,26	7,40	0,3799
GPR	21,46	$1,29 \cdot 10^3$	13,84	-0,1327
MLP	13,54	397,86	8,30	0,6651

Tabela 14 – Desempenho dos regressores para *streaming* em rede 3G

Regressor	EMA	EMQ	EMnA	R ²
OLS	$2,35 \cdot 10^5$	$1,38 \cdot 10^{11}$	$1,49 \cdot 10^5$	-0,2274
Lasso	$2,34 \cdot 10^5$	$1,21 \cdot 10^{11}$	$1,56 \cdot 10^5$	-0,0434
LARS	$2,32 \cdot 10^5$	$1,22 \cdot 10^{11}$	$1,52 \cdot 10^5$	-0,0487
SVR	$1,79 \cdot 10^5$	$1,29 \cdot 10^{11}$	$6,12 \cdot 10^4$	-0,0900
<i>Random Forest</i>	$2,08 \cdot 10^5$	$1,03 \cdot 10^{11}$	$1,15 \cdot 10^5$	0,1179
K-NN	$1,57 \cdot 10^5$	$9,24 \cdot 10^{10}$	$2,84 \cdot 10^4$	0,2317
GPR	$2,18 \cdot 10^5$	$1,17 \cdot 10^{11}$	$1,46 \cdot 10^5$	0,0014
MLP	$2,44 \cdot 10^5$	$1,03 \cdot 10^{11}$	$1,51 \cdot 10^5$	0,0939

Novamente, como o resultado para *streaming* não foi satisfatório, a atividade de *download* foi escolhida como a única para estimar o custo energético da interface de rede 3G. Apesar do modelo MLP ter se destacado devido ao valor do EMA e EMQ, foi realizada uma comparação com os modelos K-NN, *Random Forest* e Lasso, acerca do erro da ordem de grandeza de cada modelo. Os resultados estão apresentados na Tabela 14. Baseado nas medidas de erro apresentadas na Tabela 12 e na comparação da ordem de grandeza dos erros, o melhor regressor para estimar o custo energético da interface de rede 3G foi o MLP.

Tabela 15 – Comparação das ordens de grandeza das eficiências energéticas real e estimada pelos regressores para a interface de rede 3G (atividade de *download*)

Regressor	Ordem de grandeza (%)		
	Igual	Maior	Menor
<i>Random Forest</i>	94,6%	0%	5,4%
K-NN	93,3%	0%	6,7%
MLP	98,7%	0%	1,3%
Lasso	93,3%	0%	6,7%

Para a simulação, o mecanismo compara os custos energéticos associados às interfaces de rede Wi-Fi e 3G a cada coleta. Entretanto, é possível que o dispositivo se encontre em um cenário de chaveamentos sucessivos, inviabilizando seu uso em um cenário real. Dessa forma, existem algumas estratégias que podem ser utilizadas para evitar este comportamento, como aumentar o peso associado à interface de rede 3G (e.g. utilizar $C_b^{Wi-Fi} > 1,1 \cdot C_b^{3G}$ no nó de comparação da Figura, onde C_b^X é o custo energético estimado para a interface de rede X) ou manter um histórico recente do

status das interfaces de rede, de forma que seja possível identificar e impedir tal comportamento de chaveamentos sucessivos.

Inicialmente, foi realizada uma coleta, semelhante à especificada na Seção 3.2.1, de 15 minutos de utilização do *smartphone* com alto tráfego de dados e variação das condições da rede, cenário em que o mecanismo de seleção inteligente de interface de rede foi aplicado. A Figura 11 representa um trecho da coleta de dados, na qual são comparados os custos energéticos estimados para cada interface de rede. Note que valores menores de custo energético implicam em maior economia de energia (maior eficiência energética).

Comparando com o mecanismo atual do sistema operacional Android, no qual a rede Wi-Fi é utilizada constantemente, vemos que há momentos em que é mais vantajoso, do ponto de vista energético, utilizar a rede 3G. Os dados mostram que o uso do mecanismo proposto seleciona a interface de rede 3G em, aproximadamente, 26,7% do tempo.

Para estimar a economia de energia do dispositivo móvel, foi assumido que a quantidade de bytes transferidos é constante, independente da interface de rede utilizada. A estimativa da energia consumida é calculada a partir da equação E_c , definida na Seção 3.2.1, como o resultado da multiplicação do custo energético pela quantidade de bytes transferidos.

A Figura 12 ilustra a comparação das energias consumidas instantâneas estimadas do mecanismo de seleção proposto e do mecanismo nativo do sistema operacional Android. É possível notar que há uma diferença significativa na energia consumida em condições onde a rede 3G seria mais benéfica para a bateria do dispositivo móvel. Em média, essa diferença é de 48%, quando a interface 3G é mais eficiente do ponto de vista energético.

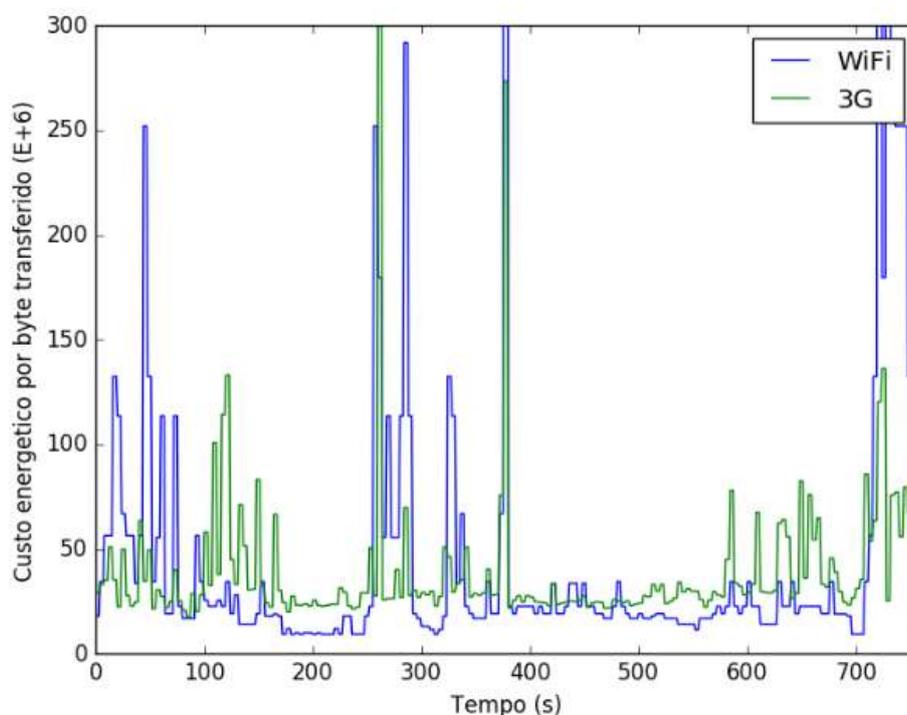


Figura 11 – Simulação da estimativa do custo energético por byte transferido para as interfaces de rede Wi-Fi e 3G

A Figura 13 apresenta a estimativa da energia total consumida pelo dispositivo móvel ao utilizar o mecanismo proposto e o mecanismo nativo. Os dados estimados para a energia consumida nos dois modos de operação de seleção de interface de rede indicam que o uso do mecanismo proposto neste trabalho gera uma economia de, aproximadamente, 11,2% neste cenário de variação das condições das redes. Entretanto, em um cenário mais realista, em que o dispositivo não está em constante movimentação, é possível que a economia de energia do dispositivo móvel seja ainda maior caso a localização do *smartphone* favoreça a interface de rede 3G.

Na prática, o objetivo final do mecanismo proposto é encontrar dinamicamente o limite da degradação do sinal de RF da interface de rede Wi-Fi que faz com que sua utilização seja a recomendada, sob o ponto de vista energético. Por se tratar de um ambiente dinâmico, não existe um limiar estático para decidir qual interface de rede utilizar. Dessa forma, é a comparação das estimativas de custo energético para cada interface de rede presente no dispositivo móvel que define a qual das interfaces o dispositivo deve se conectar.

Isto se deve ao fato, já mencionado, de que o uso da interface de rede 3G sempre tem uma potência instantânea maior que o uso da interface de rede Wi-Fi (vide Tabelas 5 e 6). Entretanto, quando a degradação da rede Wi-Fi atinge o limiar mencionado, sua taxa de transmissão decai a um ponto tal que o custo energético não justifica sua utilização frente a outras interfaces.

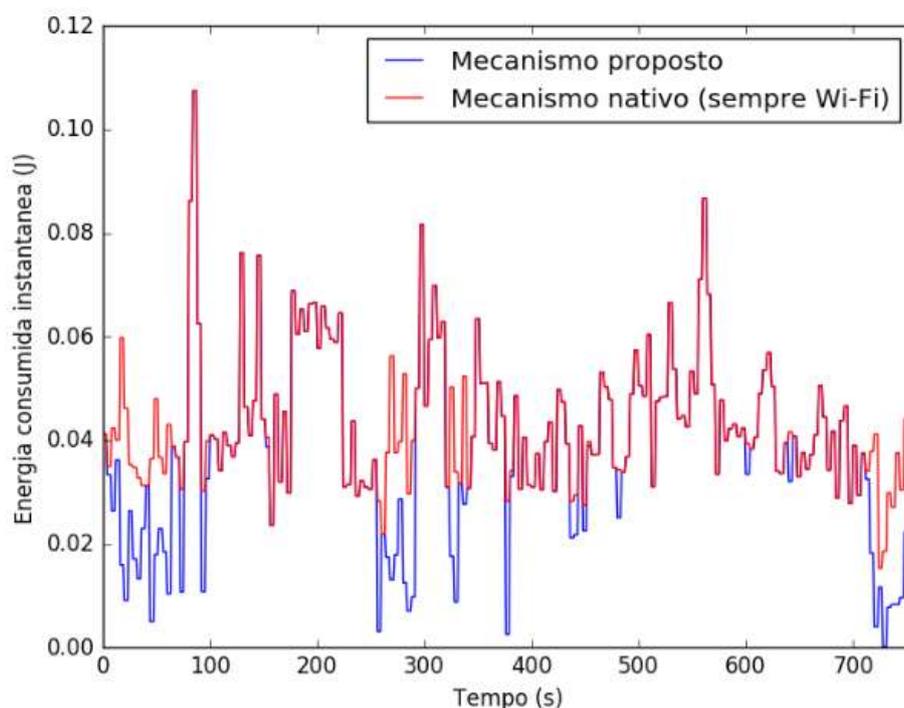


Figura 12 – Simulação da estimativa da energia consumida instantânea para os mecanismos de seleção proposto e nativo

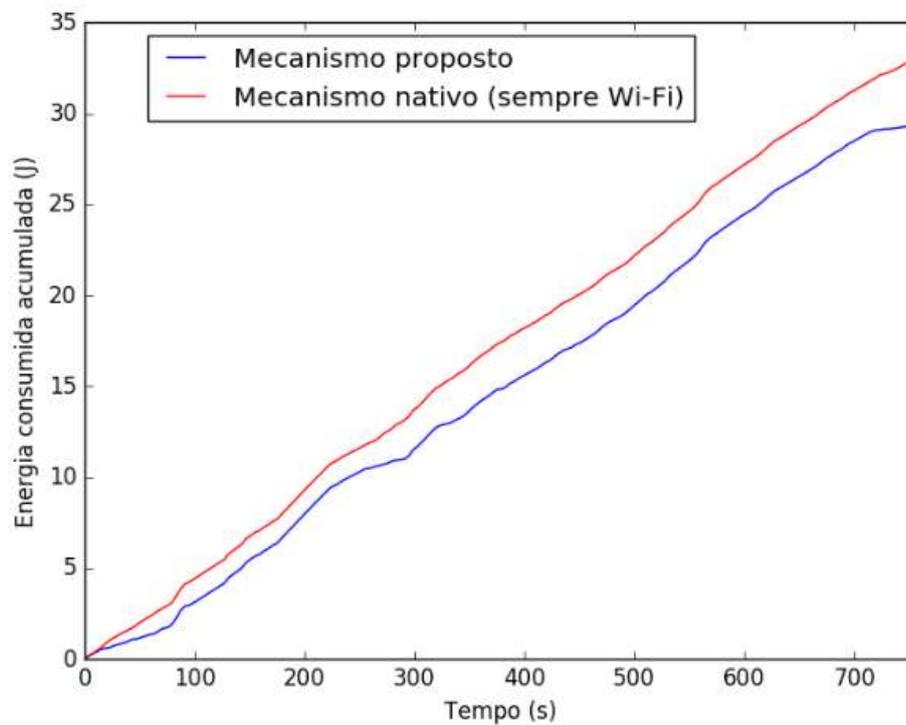


Figura 13 – Simulação da estimativa do energia consumida acumulada para os mecanismos de seleção proposto e nativo

4 CONCLUSÃO

Neste trabalho, buscamos descrever o problema de seleção de interface de rede em dispositivos móveis, explicando sua importância para a vida útil da bateria do dispositivo. Sabendo da importância de se escolher a melhor interface de rede dependendo das condições de tais redes, propomos um mecanismo capaz de observar as condições da rede e utilizar a interface de rede que otimiza o consumo de energia.

Uma contribuição deste trabalho foi mostrar que a seleção inteligente de interface pode ser feita estimando individualmente o consumo de energia de cada interface de rede. Como a estimativa é feita para cada interface de rede, a metodologia proposta pode ser estendida a outras interfaces de rede não abordadas neste trabalho, mas que possam estar presentes em um *smartphone* (por exemplo, rede LTE). Além disso, esta característica possibilita também a criação de um framework, onde será possível escolher o melhor modelo de regressão para cada interface de rede em um novo dispositivo móvel.

Outra contribuição presente neste trabalho foi a utilização de dados reais. Para tal, foi utilizado um aplicativo não comercial para coletar as informações de uso do *smartphone*, informações das condições das redes, informações de bateria e configurações do dispositivo.

Por fim, o método proposto não requer nenhuma modificação em qualquer aplicação ou no sistema operacional do dispositivo móvel Android. Desta forma, esta solução pode ser implementada sem qualquer problema em qualquer *smartphone* Android.

Por se tratar de uma área de pesquisa relativamente nova, esta dissertação proporciona algumas direções como trabalhos futuros. Um deles é a implementação real do mecanismo proposto em diferentes dispositivos móveis. Isto se daria em duas etapas: criação de um *framework* para coleta e treinamento de modelos de regressão automatizado para *smartphones* distintos e utilização do melhor modelo para cada *smartphone*. A implementação real do mecanismo proposto também viabiliza um estudo sobre o impacto da realização de *handoffs* sobre algoritmos de seleção inteligente de interface de rede, fato não investigado neste trabalho.

Pesquisas visando a inclusão da interface de rede 4G na metodologia proposta é outra possível direção futura. Embora nossa metodologia favoreça a adição de inúmeras interfaces de rede sem que a mesma seja alterada, a complexidade da rede 4G pode dificultar o treinamento de modelos de regressão e assim prejudicar o resultado final.

Outro foco de pesquisa está na investigação sobre o comportamento da atividade de *streaming*, cujas respostas dos modelos tiveram métricas de erros elevadas, impossibilitando sua utilização. Por fim, a constante criação de novos modelos de regressão viabilizam o aperfeiçoamento dos modelos utilizados, de forma que as métricas de erros diminuam ainda mais, tornando o mecanismo mais robusto.

REFERÊNCIAS

3GPP. Feasibility Study on 3GPP System to Wireless Local Area Network (WLAN). Interworking, [S.l.], 2012.

ABBAS, N.; SAADE, J. J. A fuzzy logic based approach for network selection in WLAN/3G heterogeneous network. ANNUAL IEEE CONSUMER COMMUNICATIONS AND NETWORKING CONFERENCE (CCNC), [S.l.: s.n.], p.631–636, 2015.

ABBAS, N. et al. A learning-based approach for network selection in WLAN/3G heterogeneous network. THIRD INTERNATIONAL CONFERENCE ON COMMUNICATIONS AND INFORMATION TECHNOLOGY (ICIT), [S.l.: s.n.], p.309–313, 2013.

ALPAYDIN, E. Introduction to Machine Learning, The MIT Press, [S.l.], 2014.

ALTAMIMI, M. et al. Energy-as-a-Service (EaaS): on the efficacy of multimedia cloud computing to save smartphone energy. IEEE 5TH INTERNATIONAL CONFERENCE ON CLOUD COMPUTING (CLOUD), [S.l.: s.n.], p.764–771, 2012.

ANDREUCETTI, R. et al. Smartphone energy consumption of multimedia services in heterogeneous wireless networks. INTERNATIONAL WIRELESS COMMUNICATIONS AND MOBILE COMPUTING CONFERENCE (IWCMC), [S.l.: s.n.], p.1147–1151, 2014.

AWAD, A.; MOHAMED, A.; CHIASSERINI, C. F. User-centric network selection in multi-RAT systems. IEEE WIRELESS COMMUNICATIONS AND NETWORKING CONFERENCE WORKSHOPS (WCNCW), [S.l.: s.n.], p.97–102, 2016.

BLUETOOTH SIG, I. Bluetooth Low Energy. 2017.

BORNHOLT, J.; MYTKOWICZ, T.; MCKINLEY, K. S. The model is not enough: understanding energy consumption in mobile devices. IEEE HOT CHIPS 24 SYMPOSIUM (HCS), [S.l.: s.n.], p.1–3, 2012.

BREIMAN, L. Random Forests. Machine Learning, [S.l.], v.45, n.1, p.5–32, 2001.

CARROLL, A.; HEISER, G. An Analysis of Power Consumption in a Smartphone. USENIX CONFERENCE ON USENIX ANNUAL TECHNICAL CONFERENCE p.21, 2010.

CHATTERJEE, S.; HADI, A. S. Regression Analysis by Example, 4th Edition. Wiley-Interscience, [S.l.], 2006.

CHOWDHURY, M. Z. et al. Interface selection for power management in UMTS/WLAN overlaying network. 11TH INTERNATIONAL CONFERENCE ON ADVANCED COMMUNICATION TECHNOLOGY (ICACT), [S.l.: s.n.], v.01, p.795–799, 2009.

CISCO SYSTEMS, I. Cisco VNI Forecast and Methodology, 2015-2020. CiscoSystems, Inc., [S.l.], 2016.

DING, N. et al. Characterizing and Modeling the Impact of Wireless Signal Strength on Smartphone Battery Drain. ACM SIGMETRICS/INTERNATIONAL CONFERENCE ON MEASUREMENT AND MODELING OF COMPUTER SYSTEMS (SIGMETRICS), p.29–40, 2013.

DUDA, R. O.; HART, P. E.; STORK, D. G. Pattern Classification (2nd Edition). Wiley-Interscience, [S.l.], 2000.

ERICSSON. Ericsson Mobility Report. Ericsson, [S.l.], 2016.

FERNÁNDEZ-DELGADO, M. et al. Do we Need Hundreds of Classifiers to Solve Real World Classification Problems? Journal of Machine Learning Research, [S.l.], v.15, p.3133–3181, 2014.

GAO, W.; ZHANG, W. Conserving mobile terminal's energy using a novel network selection mechanism in integrated UMTS/WLANs. INTERNATIONAL CONFERENCE AND WORKSHOP ON COMPUTING AND COMMUNICATION (IEMCON), [S.l.: s.n.], p.1–5, 2015.

GONZALEZ, F. Advanced and Post Lithium-ion Batteries 2016-2026: technologies, markets, forecasts. IDTechEx, [S.l.], 2016.

GUYON, I. et al. Gene Selection for Cancer Classification Using Support Vector Machines. Mach. Learn., v.46, n.1-3, p.389–422, 2002.

HADDAD, M. et al. An Automated Dynamic Offset for Network Selection in Heterogeneous Networks. IEEE Transactions on Mobile Computing, [S.l.], v.15, n.9, p.2151–2164, 2016.

HASTIE, T.; TIBSHIRANI, R.; WAINWRIGHT, M. Statistical Learning with Sparsity: the lasso and generalizations. Chapman & Hall/CRC, [S.l.], 2015.

HOQUE, M. A.; TARKOMA, S. Sudden Drop in the Battery Level?: understanding smartphone state of charge anomaly. WORKSHOP ON POWER-AWARE COMPUTING AND SYSTEMS, p.26–30, 2015.

KELLOKOSKI, J.; KOSKINEN, J.; HAMALAINEN, T. Power Consumption Analysis of the Always-Best-Connected User Equipment. INTERNATIONAL CONFERENCE ON NEW TECHNOLOGIES, MOBILITY AND SECURITY (NTMS), [S.l.: s.n.], p.1–5, 2012.

KOENIG, I.; MEMON, A. Q.; DAVID, K. Energy consumption of the sensors of Smartphones. THE TENTH INTERNATIONAL SYMPOSIUM ON WIRELESS COMMUNICATION SYSTEMS, [S.l.: s.n.], p.1–5, 2013.

KOLAY, N.; ERDOGMUS, P. The classification of breast cancer with Machine Learning Techniques. ELECTRIC ELECTRONICS, COMPUTER SCIENCE, BIOMEDICAL ENGINEERINGS' MEETING (EBBT), [S.l.: s.n.], p.1–4, 2016.

KUHN, M.; JOHNSON, K. Applied Predictive Modeling. New York: Springer, 2013.

KUNCHEVA, L. I. Combining Pattern Classifiers: methods and algorithms. Wiley-Interscience, [S.l.], 2004.

LAI, Y.; CHAIT, K. K.; CHEN, Y. A utility-based intelligent network selection for 3G and WLAN heterogeneous networks. INTERNATIONAL CONFERENCE ON WIRELESS COMMUNICATIONS AND APPLICATIONS (ICWCA 2012), [S.l.: s.n.], p.1–6, 2012.

LI, X. et al. Measurement and analysis of energy consumption on Android smartphones. IEEE INTERNATIONAL CONFERENCE ON INFORMATION SCIENCE AND TECHNOLOGY, [S.l.: s.n.], p.242–245, 2014.

MITCHELL, T. M. Machine Learning. 1.ed. New York, NY, USA: McGraw-Hill, Inc., 1997.

MONTENEGRO, G. et al. IPv6 over Low-Power Wireless Personal Area Network. IETF, [S.l.], 2007

PEDREGOSA, F. et al. Scikit-learn: machine learning in Python. Journal of Machine Learning Research, [S.l.], v.12, p.2825–2830, 2011.

PERRUCCI, G. P.; FITZEK, F. H. P.; WIDMER, J. Survey on Energy Consumption Entities on the Smartphone Platform. IEEE 73RD, VEHICULAR TECHNOLOGY CONFERENCE (VTC SPRING), [S.l.: s.n.], p.1–6, 2011.

PRABHAVATHI, P.; NITHYANANDAN, L. Network selection in wireless heterogeneous networks. INTERNATIONAL CONFERENCE ON COMMUNICATIONS AND SIGNAL PROCESSING (ICCSP), [S.l.: s.n.], p.357–361, 2013.

RASMUSSEN, C. E.; WILLIAMS, C. K. I. Gaussian Processes for Machine Learning (Adaptive Computation and Machine Learning). The MIT Press , [S.l.], 2005.

RUMNEY, M. LTE and the Evolution to 4G Wireless: design and measurement challenges. Wiley Publishing, [S.l.], 2013.

SHEARER, F. Power Management in Mobile Devices. Newnes, 2007.

SMOLA, A. J.; SCHÖLKOPF, B. A Tutorial on Support Vector Regression. Statistics and Computing, v.14, n.3, p.199–222, 2004.

SONG, Q.; JAMALIPOUR, A. Network selection in an integrated wireless LAN and UMTS environment using mathematical modeling and computing techniques, IEEE Wireless Communications, [S.l.], v.12, n.3, p.42–48, 2005.

WOLPERT, D. H.; MACREADY, W. G. No Free Lunch Theorems for Optimization. IEEE TRANSACTIONS ON EVOLUTIONARY COMPUTATION, v.1, n.1, p.67–82, 1997.

ZHAO, L. et al. A SVM based routing scheme in VANETs. INTERNATIONAL SYMPOSIUM ON COMMUNICATIONS AND INFORMATION TECHNOLOGIES (ISCIT),[S.l.: s.n.], p.380–383, 2016.

APÊNDICE A – PARÂMETROS DOS MODELOS DE REGRESSÃO

Tabela A.1: Parâmetros utilizados com *Random Forest* para Wi-Fi e 3G.

Interface e atividade	Número de estimadores (N)	Número de características (M)
Wi-Fi download	2	9
Wi-Fi streaming	3	4
Wi-Fi (download e streaming)	4	12
3G download	33	4
3G streaming	12	4
3G (download e streaming)	3	12

Tabela A.2: Parâmetros utilizados com *K-NN* para Wi-Fi e 3G.

Interface e atividade	Número de vizinhos (K)
Wi-Fi download	2
Wi-Fi streaming	3
Wi-Fi (download e streaming)	4
3G download	33
3G streaming	12
3G (download e streaming)	3

Tabela A.3: Parâmetros da MLP para Wi-Fi e 3G.

Interface e atividade	<i>Solver</i>	<i>Activation</i>	<i>Alpha</i>	<i>Learning rate</i>	<i>Hidden layer</i>
Wi-Fi download	lbfgs	tanh	10^{-5}	adaptive	(50)
Wi-Fi streaming	lbfgs	relu	1	adaptive	(25,12)
Wi-Fi (download e streaming)	lbfgs	tanh	$5 \cdot 10^{-3}$	adaptive	(25,12)
3G download	lbfgs	relu	$5 \cdot 10^{-1}$	adaptive	(25,12)
3G streaming	lbfgs	tanh	10^{-4}	adaptive	(50)
3G (download e streaming)	lbfgs	tanh	10^{-3}	adaptive	(50)