



Impactos Socioeconômicos das Operações do iFood no Brasil: **Análise sobre os Entregadores**

Renato S Vieira

Ricardo C A Lima

Pedro J H Alves

Gabriella N C Rodrigues

2021

Um estudo **FIPE**

fipe
Fundação Instituto de
Pesquisas Econômicas

SUMÁRIO

EXECUTIVO

Esta seção analisa os entregadores da plataforma do iFood, buscando identificar o perfil desses trabalhadores, a remuneração frente a outras ocupações e características regionais do mercado de trabalho. Com base no cruzamento dos dados dos entregadores do iFood com a base identificada da RAIS, foram realizadas duas análises:

1 – Foi avaliado como a remuneração dos entregadores se compara com o quanto se esperaria que eles ganhassem no mercado formal tradicional. Cada entregador do iFood previamente observado em um emprego formal foi pareado com outro trabalhador com características similares. A evolução desses dois grupos foi, então, comparada. Os resultados dessa análise indicam que:

- Se considerarmos somente o período efetivamente gasto nas entregas, os ganhos médios por hora trabalhada no iFood são equivalentes 165,5% da remuneração por hora que os trabalhadores teriam no mercado formal. Caso seja considerado o tempo ocioso em que os trabalhadores estão conectados à plataforma mas não estão realizando entregas, os ganhos médios por hora trabalhada no iFood seriam equivalentes a 96,5% da remuneração por hora esperada no mercado formal.
- Importantes disparidades regionais foram observadas com relação a esse resultado, tendo a região Sul apresentado o maior bônus salarial para os entregadores do iFood e a região Norte, o menor.



2 – Analisamos como características individuais, como raça e gênero, afetam a remuneração dos trabalhadores tanto no iFood quanto no mercado formal. Os resultados dessa análise mostraram que:

- No mercado formal, mesmo controlando para características observáveis, como nível educacional e ocupação, existem diferenças significativas de diferenças salariais, com mulheres ganhando 5,64% menos que homens. E negros ganhando, em média, 0,63% a menos que brancos.

- Tais diferenças são substancialmente reduzidas, e em muitos casos eliminadas, quando analisamos os mesmos indivíduos trabalhando como entregadores na plataforma do iFood.

- No caso do diferencial de gênero, mesmo na plataforma ainda é observado uma discrepância de 1,38% na remuneração das mulheres. Entretanto, nossas análises indicam que tal diferencial pode ser totalmente explicado pelo menor uso de motocicleta quando comparado aos entregadores homens.

Dessa forma, as principais conclusões dessa seção são que os trabalhadores do iFood recebem uma remuneração por hora trabalhada compatível com a que receberiam caso estivessem empregados no setor formal e que o trabalho no iFood atenua e em muitos casos elimina os diferenciais salariais observados pelos trabalhadores no mercado tradicional.

1. INTRODUÇÃO

A *gig economy*¹ é um fenômeno global que tem alterado as dinâmicas do mercado de trabalho em um número crescente de setores. Esse novo tipo de arranjo do trabalho se caracteriza pela utilização de plataformas digitais que conectam prestadores de serviços autônomos com seus consumidores. Tal configuração reduz as barreiras de entrada facilitando e barateando a prestação de serviços por parte dos trabalhadores autônomos. Por outro lado, as incertezas relativas à renda e à demanda pelo trabalho também são exacerbadas, pois passam a depender de um agente intermediário com potencial poder de mercado. Assim, a *gig economy* acentua o clássico *tradeoff* entre a flexibilidade proporcionada pelo trabalho autônomo e a estabilidade de renda assegurada nos contratos de emprego tradicionais.

Com a expansão da *gig economy* em todo o mundo, torna-se cada vez mais importante entender os custos e benefícios dessa forma de arranjo do trabalho. No que se refere aos prestadores de serviço dessas plataformas, destacam-se as seguintes perguntas: Como a remuneração na *gig economy* se compara com a dos empregos tradicionais? Tal comparação é homogênea nas diferentes regiões ou é mais acentuada em alguns locais específicos? Quais características dos indivíduos estão associadas a uma maior ou menor remuneração na *gig economy*? Como essa relação entre características individuais e remuneração se compara com o caso dos empregos tradicionais?

¹ Não há ainda uma definição formal e amplamente aceita do termo *gig economy*. A OCDE classifica a *gig economy* como plataformas digitais bilaterais que combinam os prestadores de serviços de um lado com os clientes (consumidores finais ou empresas) do outro. Tal definição exclui plataformas unilaterais como a Amazon (comércio de mercadorias), e plataformas bilaterais que não intermediam mão-de-obra, como o Airbnb (intermediação de serviços de acomodação) (OECD, 2019). Por essa definição, a *gig economy* se caracteriza como um subconjunto da chamada “economia de compartilhamento”, que engloba todos os tipos de plataformas multilaterais de conexão entre usuários.

Este estudo investiga tais questões analisando os trabalhadores que prestam serviços de entrega no Brasil utilizando a plataforma *iFood*, empresa da *gig economy* líder no segmento de entrega de alimentos no país. Especificamente, com base nos dados das entregas realizadas ao longo dos anos de 2019 e 2020, são analisados os ganhos de 497.743 trabalhadores da plataforma. Essa remuneração é avaliada conforme as seguintes estratégias de análise:

1. Combinando os dados do *iFood* com os microdados identificados da RAIS, nós avaliamos a evolução na remuneração dos indivíduos que ingressaram na plataforma e que anteriormente estavam empregados no setor formal. Para avaliar como a entrada na plataforma afeta a remuneração dos indivíduos, nós construímos os ganhos contrafactuais desses trabalhadores através de um grupo de controle construído por um método de pareamento por escore de propensão (*Propensity Score Matching*) que seleciona indivíduos no mercado formal com características observáveis próximas à dos trabalhadores que ingressaram na plataforma mas que se mantiveram com um emprego formal. Ou seja, a evolução dos ganhos dos indivíduos que ingressaram na plataforma é comparada com a evolução equivalente dos trabalhadores desse grupo de controle.
2. Em uma análise adicional, a remuneração dos entregadores é avaliada através de uma regressão Minceriana que busca estimar a associação entre a remuneração dos trabalhadores com características observadas dos mesmos tais como experiência, educação, gênero, raça, idade, etc. Os coeficientes dessa regressão são estimados tanto para os ganhos na plataforma quanto para a remuneração obtida por esses mesmos indivíduos quando atuavam no mercado formal tradicional, permitindo assim uma comparação de questões tais como o diferencial de remuneração por gênero e raça tanto na plataforma quanto no mercado formal para esses indivíduos.

Os resultados da primeira estratégia indicam que a remuneração por hora efetivamente trabalhada no *iFood* é 67,7% superior à remuneração esperada caso tais trabalhadores estivessem empregados no setor formal. Vale destacar que tal resultado precisa ser avaliado com cautela dado que considera como “hora trabalhada” na plataforma do *iFood* somente o período em que um entregador está efetivamente realizando uma entrega, isso é, o intervalo de tempo entre o desígnio de uma entrega ao trabalhador pela plataforma e o fechamento da entrega ao cliente no sistema. Entretanto, para cada entrega realizada, o entregador passa um período de tempo não observável aguardando ser selecionado para alguma entrega e, em alguns casos, se deslocando de volta após a finalização do *delivery*. Com base em uma amostra de entregas onde foi registrado o

período em que os trabalhadores ficam conectados à plataforma, nós estimamos que para cada 1 minuto despendido em entrega, os trabalhadores passam em média 1,14 minutos adicionais logados na plataforma. Caso esse tempo logado fosse integralmente considerado no cômputo do salário-hora no *iFood*, o resultado da nossa estimação indicaria que a remuneração por hora trabalhada dos entregadores seria 3,5% inferior à remuneração esperada para esses mesmos trabalhadores no setor formal. Entretanto, da mesma forma que não consideramos ideal ignorar completamente o tempo de espera no cálculo do salário-hora, também não é razoável considerar que tal tempo ocioso seja considerado de forma equivalente ao tempo efetivamente gasto realizando entregas pelos trabalhadores, pois nesse período logado, mas ocioso na plataforma, é possível que os trabalhadores estejam realizando outras atividades, incluindo serviços de entrega em plataformas semelhantes ao *iFood*.

Dessa forma, consideramos que a forma mais adequada de interpretar os nossos resultados é que os coeficientes de +67,7% e -3,5% representam os limites do diferencial médio entre a remuneração por hora-trabalhada no *iFood* e no mercado formal a depender de como consideramos o período ocioso com relação ao período efetivamente trabalhado. O coeficiente de +67,7% representa a diferença salarial caso o tempo em espera pudesse ser completamente descartado, ou seja, caso representasse um gasto de tempo por parte do trabalhador. Já o coeficiente de -3,5% seria observado caso o tempo em espera fosse considerado exatamente igual ao tempo em entrega. O mais provável é que nenhum desses casos extremos seja válido, estando o diferencial real em algum ponto intermediário dentro desse intervalo.

Já os resultados da segunda estratégia revelam que no mercado de trabalho tradicional é observado um diferencial de salário significativo de gênero e raça, com mulheres e não-brancos recebendo uma remuneração média inferior à remuneração dos trabalhadores homens e brancos com características observáveis equivalentes. Já na plataforma do *iFood*, a remuneração dos trabalhadores não possui diferenças significativas residuais com relação ao gênero e à raça dos entregadores. Tal resultado sugere que o pagamento dos entregadores na plataforma é de fato neutro com relação a características usualmente sujeitas a discriminação no mercado de trabalho.

O restante desse capítulo é dividido da seguinte forma: a Seção 2 detalha as bases de dados utilizadas nas estratégias de análise. A Seção 3 discute o modelo utilizado para comparar a remuneração dos entregadores com a remuneração de trabalhadores



ANJOS
DE CAPACETE

NAR
7271
TAM
60

ifood

2. DADOS

Impacto Econômico Sistêmico

Em 2020, a cadeia de valor do segmento de entregas por aplicativo (iFood) foi responsável pela geração de:

- R\$ 31,8 bilhões do PIB nacional, o que corresponde a **0,43% do PIB de 2020**
 - o R\$ 15,2 bilhões (0,65 % do PIB estadual) em São Paulo
 - o R\$ 3,5 bilhões (0,47 % do PIB estadual) no Rio de Janeiro
 - o R\$ 13,1 bilhões nas demais UF's
- Cerca de **730 mil postos de trabalho** (formal e informal), o equivalente a 0,72% da população ocupada em 2020


2.1. Dados iFood sobre trabalhadores que prestam serviços de entrega

Os dados utilizados nessa seção do estudo partem dos registros de 181,2 milhões de entregas realizadas por 497.743 entregadores parceiros do iFood entre 1º de janeiro de 2019 e 31 de dezembro de 2020. Vale notar que tais entregas correspondem à parcela de entregas feitas pelo aplicativo e cuja remuneração do entregador foi responsabilidade da própria plataforma. Outras formas de entrega, como por exemplo aquelas em que o restaurante é o responsável pela entrega e pela remuneração do entregador, não são incluídas em nossa análise.

A Figura 1 avalia a evolução mensal de algumas características das entregas utilizadas em nossas análises, incluindo: o número de entregas por mês, o número de entregadores ativos a cada mês, o percentual de entregas por modal, a distância linear média, a duração das entregas e a remuneração básica dos entregadores. Entre 2019 e 2020, o total de entregas mensais observadas aumentou de 2,4 milhões em janeiro de 2019 para 14,9 milhões em dezembro de 2020, representando um aumento de 520%. Da

mesma forma, o total de entregadores ativos a cada mês foi de 47 mil para 161 mil, correspondendo a uma elevação de 242%.

Figura 1 – Evolução mensal das características das entregas próprias (nuvem) do iFood



Fonte: base de rotas do iFood

No início de 2019, quase todas as entregas eram feitas de moto, mas essa proporção se reduz gradualmente ao longo do tempo conforme ilustrado no painel C da Figura 1. Em dezembro de 2020, cerca de 12% das entregas já eram feitas de bicicleta. Outros modais como patinete e bicicleta elétrica ainda seguem representando uma parcela reduzida das entregas, tendo alcançado o percentual máximo de 2,6% em novembro de 2020. O tempo médio por entrega oscilou ao longo de todo o período ao redor de 24 minutos, tendo sido observada uma significativa redução em novembro e dezembro de 2020. Por fim, os painéis E e F mostram que a distância linear média por entrega oscilou em torno de 5,66km, e a remuneração média dos entregadores foi de R\$9,02² por entrega.

2.2. RAIS

Para incorporar as informações sobre os trabalhadores em empregos formais tradicionais, nós compilamos o conjunto de microdados da Relação Anual de Informações Sociais (RAIS) entre 2014 e 2019. A RAIS é um conjunto de dados disponibilizado pelo Ministério do Trabalho e Emprego³, cuja finalidade é disponibilizar informações cadastrais de todos os empregados com carteira assinada e de todas as empresas cadastradas no Cadastro Nacional da Pessoa Jurídica (CNPJ). O governo utiliza essa base como uma forma de controlar questões fiscais, como o recolhimento do imposto de renda e outros impostos direcionados às empresas. Todas as empresas são obrigadas pelo Governo Federal a declarar informações sobre seus estabelecimentos e seus respectivos empregados.

A base original da RAIS tinha em 2018 aproximadamente 66,2 milhões de registros de pessoas com carteira assinada. A partir da base original, nós aplicamos filtros e restrições como forma de remover os registros que não foram preenchidos da forma correta. O primeiro passo foi remover qualquer trabalhador formal que tenha sido desligado durante o ano. Para isso, mantivemos apenas os trabalhadores que tinham vínculo empregatício em dezembro de cada ano. Para remover os registros mal preenchidos, nós selecionamos apenas os trabalhadores os trabalhadores: i) com renda maior que zero; ii) idade entre 16 e 80 anos; iii) registro de horas trabalhadas semanais maior que um; iv)

² Por conta do curto período analisado, optou-se por utilizar em toda essa seção do relatório valores correntes, não sendo feito nenhum ajuste para a inflação.

³ Antes vinculada ao Ministério da Economia.



que tinham registro da Classificação Brasileira de Ocupações (CBO); v) sem informações duplicadas de trabalhadores, mantendo em tais casos apenas a informação do empregado com maior salário.

Após esses filtros, nossa amostra manteve 43,9 milhões de registros, ou 66,3% da base original em 2018. Por fim, cruzamos os CPFs criptografados dos trabalhadores com os dados da base de entregadores do *iFood* de 2019/2020, encontrando 29,31% dos entregadores na RAIS em 2018 e 50,9% dos entregadores *iFood* em algum período entre 2014-2019.

2.3. Cálculo do salário-hora no *iFood* e na RAIS

Nossa principal variável de interesse em nossas análises é a remuneração líquida por hora trabalhada, que pode ser considerada como uma medida da produtividade do trabalhador e é comparável entre os trabalhadores autônomos e os empregados tradicionais.

Para que tal medida fosse calculada para os trabalhadores observados na RAIS, o primeiro passo foi incluir na remuneração bruta o ganho anual com o 13º salário, imposto pela Lei nº 4.090/1962 que prevê o acréscimo de um mês de salário a cada um ano de trabalho. O segundo passo foi descontar do Imposto de Renda (IR) a partir da Medida Provisória nº 670, de 10 de março de 2015. Seguindo a MP o desconto foi feito de acordo com a faixa salarial

de cada empregado. Em seguida, foram adicionados os benefícios não salariais de cada empregado, como vale-alimentação (ou auxílio-alimentação). Por fim, a remuneração bruta resultante desse cálculo foi dividida pelo número de horas contratadas, resultando assim em uma medida da remuneração líquida por hora contratada desses trabalhadores.

No caso dos entregadores do *iFood* a remuneração líquida foi calculada com base nos pagamentos realizados pela plataforma, descontados os custos estimados por deslocamento. Tais custos foram calculados com base em um parâmetro de R\$0,27 por km rodado nas entregas feitas de moto baseado no trabalho de Nunes & Ferrari (2019). Já para as entregas feitas de bicicleta, assumiu-se que o entregador não possui nenhum custo. Por fim, tal remuneração líquida é dividida por duas medidas alternativas relativas ao tempo de entrega: 1) o tempo efetivamente gasto em cada entrega, calculado como a diferença entre o *timestamp* de alocação do trabalhador para uma determinada entrega, menos o *timestamp* de conclusão dessa mesma entrega; e 2) uma estimativa do tempo total conectado à plataforma em cada entrega, ou seja, incorporando além do tempo mensurado pela primeira medida, o tempo gasto pelo entregador logado no sistema aguardando ser conectado a um pedido. Ou seja, a diferença entre essas medidas refere-se ao tratamento do tempo ocioso, a primeira medida descarta o tempo em que o trabalhador está conectado à plataforma mas não está realizando nenhuma entrega; já a segunda medida considera que tal tempo é equivalente ao tempo efetivamente trabalhado, somando-se ambos os valores sem qualquer ponderação para o cômputo do tempo trabalhado por entrega. Pode-se argumentar que nenhuma das medidas é ideal, pois o valor do tempo ocioso não deve ser nem completamente negligenciado nem considerado equivalente ao tempo despendido em entregas. Assim, o valor real do tempo ocioso deve ser algum valor intermediário entre esses dois extremos. Dessa forma, as medidas de que calculamos para a remuneração por hora trabalhada na plataforma do *iFood* devem ser interpretadas como os limites inferior e superior dessa remuneração.

3. EFEITOS DO *IFOOD* SOBRE O RENDIMENTO DOS TRABALHADORES.

O objetivo dessa seção é avaliar o impacto do *iFood* sobre os rendimentos dos trabalhadores que se moveram do setor formal da economia para a plataforma de *delivery*. Em primeiro lugar, a subseção 3.1 apresenta os detalhes da construção de um painel de dados que será usado nesse exercício e que combina as bases de dados da RAIS com a base do *iFood*. Em seguida, a subseção 3.2 descreve a estratégia utilizada para obtenção de um grupo de controle adequado e a subseção 3.3 apresenta a estratégia empírica para avaliar o efeito de entrada na plataforma na remuneração. Por último, a subseção 3.4 apresenta os resultados da estimação e discute as principais implicações desse exercício.

3.1. Combinação das Bases de Dados

Nós combinamos as informações da RAIS e do *iFood* fazendo um empilhamento das bases da RAIS de 2014 a 2019 com a base do *iFood* de 2019. O identificador anonimizado do trabalhador é usado para fazer o rastreamento e o acompanhamento de cada indivíduo ao longo do tempo. Assim, a base é formada por um painel contendo dois grupos distintos de trabalhadores: aqueles observados na RAIS e também no *iFood* em 2019 e aqueles observados apenas na RAIS. O primeiro grupo é definido como o grupo de tratamento e o segundo grupo formará nosso *pool* de potenciais controles.



Três restrições adicionais são feitas nessa base de dados.

- Primeiramente, eliminamos os entregadores do *iFood* em 2019 e que não foram encontrados na RAIS, ou seja, que não participavam do mercado de trabalho formal antes de operarem na plataforma de *delivery*. Essa restrição é necessária para permitir o acompanhamento da evolução dos rendimentos dos trabalhadores que se moveram para o *iFood* e, dessa forma, avaliar o efeito da plataforma. Com essa restrição, mantemos 17.434 entregadores do *iFood* na nossa base final, o que representa 11,8% da base inicial selecionada.
- Em segundo lugar, eliminamos os trabalhadores que estavam simultaneamente no mercado de trabalho formal e realizam entregas por meio do *iFood* em 2019. Esses indivíduos não podem ser separados entre o grupo de tratamento e o grupo de controle e representam 22,1% da base do *iFood*.
- Por último, fazemos uma restrição no potencial grupo de controle para deixá-lo comparável ao grupo de tratamento. Mais especificamente, nós restringimos esse grupo para manter apenas os indivíduos que estavam ocupados em 2019, uma vez que por definição, todo o grupo de tratamento estava ocupado em 2019. Com essa restrição, eliminamos 1.682.376 observações da base da RAIS de 2018, valor que representa 3,7% da base.



3.2. Definição do grupo de controle com base em um procedimento de pareamento

Os trabalhadores que ingressam na plataforma do *iFood* não constituem um grupo aleatório de trabalhadores, possuindo características específicas que impedem a comparação direta com a média dos demais trabalhadores brasileiros. Assim, com o objetivo de construir um grupo de controle adequado, nós adotamos um procedimento de pareamento para selecionar do *pool* total de

trabalhadores de controle uma subamostra de indivíduos com características pré-tratamento similares às características do grupo de trabalhadores que se moveram para o *iFood*. Além de ser útil para deixar o grupo de controle mais parecido com o grupo de tratamento (o que tende a reduzir um potencial viés de seleção), o pré-processamento com pareamento gera estimadores mais eficientes e menos dependentes de especificações paramétricas (Ho et al. 2006). Para executar esse procedimento, nós utilizamos informações do ano de 2018 para parear cada um dos trabalhadores parceiros do *iFood* com um trabalhador de controle com base nas seguintes características observáveis: rendimento (mensurado em salário-hora), faixas de idade, gênero, raça, faixas de educação, faixas de ocupação (2 dígitos) e indicador de deficiência.

O pareamento é feito em duas etapas. Primeiro, um modelo de regressão probabilístico⁴ é usado para prever, para cada trabalhador específico, a probabilidade de receber o tratamento (isso é, se mover para o *iFood*) dado o seu conjunto de variáveis observadas. Essas estimativas de probabilidades são chamadas de *propensity scores*. A segunda etapa é utilizar um algoritmo para encontrar indivíduos do *pool* de controles que tenham o *propensity score* mais próximo possível de cada um dos indivíduos que compõem o grupo de tratamento e que se localizavam em um mesmo município. Utilizamos o algoritmo de vizinho mais próximo sem reposição para fazer o pareamento, o que nos possibilita obter um indivíduo de controle para cada indivíduo tratado. Para fins de robustez, iremos também aplicar outros dois algoritmos tradicionais: o *radius matching* e o *optimal pair matching*. Caliendo e Kopeinig (2008) apresenta os detalhes de cada um dos principais algoritmos de pareamento e discute questões de viés e de eficiência em cada uma das abordagens.

A Tabela 1 apresenta a comparação das médias de cada uma das variáveis socioeconômicas para o grupo tratado e para o grupo de controle antes do pareamento (Colunas (1) e (2)) e após o pareamento (Colunas (4) e (5)). A coluna (3) e (6) mostram as respectivas diferenças de médias. É possível notar que, antes do pareamento, os indivíduos que se moveram para o *iFood* são, em média, bem diferentes dos outros trabalhadores do mercado formal (Coluna (1) e (2)). Em geral, observa-se que em relação ao universo dos trabalhadores formais, o grupo de trabalhadores tratados apresentava uma menor média de salário-hora, menor proporção de deficientes físicos, menor proporção de mulheres, menor proporção de brancos, menor proporção de escolaridade

⁴ Mais especificamente, é estimado um modelo logit em que a variável dependente é a participação na plataforma de entrega de comida (assume 1 para indivíduos que se moveram para o *iFood* e assume 0, caso contrário) e o vetor de controles é formado pelas seguintes variáveis: rendimento, faixas de idade, gênero, raça, faixas de educação, faixas de ocupação (2 dígitos), indicador de deficiência e macrorregião de trabalho.

de nível ensino superior e maior de nível médio, e concentravam-se nas faixas de menor idade e nas ocupações ligadas ao setor de comércio e vendas. Após a realização do pareamento (Coluna (4) e (5)), essas diferenças de médias praticamente somem, de forma que o grupo de controle pareado torna-se muito semelhante ao grupo de indivíduos que se moveram para o *iFood*. A Figura 2 apresenta visualmente as diferenças detalhadas na Tabela 1. No painel A da figura, os pontos vermelhos indicam a média de cada variável na amostra de trabalhadores do *iFood*, já os pontos em azul representam a média do pool completo de trabalhadores observados na RAIS, e as barras cinza indicam a diferença entre essas médias. Já no painel B, as médias da RAIS são substituídas pelas médias do grupo de controle selecionado no processo de pareamento, ficando evidente a redução da diferença entre os grupos.


Tabela 1 – Média das variáveis socioeconômicas do grupo de tratamento e do grupo de controle, antes e depois do pareamento.

Variável	Antes do Pareamento			Após o Pareamento		
	(1)	(2)	(3)	(4)	(5)	(6)
	Tratado	Controle	Diferença	Tratado	Controle	Diferença
Salário-Hora (Em R\$)	9,48	19,89	-10,41 ***	9,48	9,45	0,03
Deficiência Física (0/1)	0,00	0,01	-0,01 ***	0,00	0,01	0,00
Sexo Feminino (0/1)	0,04	0,45	-0,41 ***	0,04	0,04	0,00
Cor Branca (0/1)	0,56	0,60	-0,04 ***	0,56	0,56	0,00
Ensino						
Sem Escolaridade (0/1)	0,01	0,03	-0,02 ***	0,01	0,01	0,00
Fundamental Completo (0/1)	0,11	0,12	0,00	0,11	0,12	0,00
Médio Completo (0/1)	0,82	0,55	0,27 ***	0,82	0,82	0,00
Superior Completo (0/1)	0,05	0,30	-0,25 ***	0,05	0,05	0,00
Idade						
Menos de 25 anos (0/1)	0,48	0,15	0,33 ***	0,48	0,47	0,01 *
Entre 26 a 35 anos (0/1)	0,38	0,34	0,04 ***	0,38	0,39	-0,01 **
Entre 36 a 45 anos (0/1)	0,11	0,22	-0,12 ***	0,11	0,11	0,00
46 anos ou mais (0/1)	0,03	0,29	-0,26 ***	0,03	0,03	0,00
Ocupação						
Forças Armadas (0/1)	0,02	0,02	0,00 ***	0,02	0,02	0,00
Serviço Público (0/1)	0,01	0,06	-0,05 ***	0,01	0,01	0,00
Ciência e Artes (0/1)	0,01	0,12	-0,11 ***	0,01	0,01	0,00
Técnico de Nível Médio (0/1)	0,05	0,13	-0,08 ***	0,05	0,06	0,00
Serviço Administrativo (0/1)	0,17	0,21	-0,04 ***	0,17	0,18	-0,01 **
Comércio e Vendas (0/1)	0,49	0,25	0,24 ***	0,49	0,47	0,02 ***
Agropecuária (0/1)	0,00	0,01	-0,01 ***	0,00	0,00	0,00
Indústria de Transformação (0/1)	0,19	0,15	0,04 ***	0,19	0,20	-0,01
Outras Indústrias (0/1)	0,03	0,03	0,00 ***	0,03	0,03	0,00
Serviços de Reparação (0/1)	0,03	0,02	0,01 ***	0,03	0,03	0,00


Nota: A tabela mostra a comparação de média de cada uma das variáveis socioeconômicas para o grupo de tratamento (trabalhadores que se moveram para o iFood) e para o grupo de controle (trabalhadores que permaneceram no mercado formal de trabalho) antes do pareamento (coluna (1), (2)) e depois do pareamento (Coluna (4) e (5)). Utiliza-se o método do vizinho mais próximo por grupo de município para realizar o pareamento. *** $p < 0,01$, ** $p < 0,05$ e * $p < 0,1$.

Figura 2 – Média das variáveis socioeconômicas do grupo de tratamento e do grupo de controle, antes e depois do pareamento.

(A) – Antes do pareamento



(B) – Após o matching



Nota: A figura mostra a comparação de média de cada uma das variáveis socioeconômicas para o grupo de tratamento (trabalhadores que se moveram para o *iFood*) e para o grupo de controle (trabalhadores que permaneceram no mercado formal de trabalho) antes do pareamento (painel A) e após o pareamento (painel B).

3.3. Estratégia Empírica

Para avaliar o impacto da participação no *iFood* sobre a renda dos trabalhadores que se moveram do mercado de trabalho formal para a plataforma de *delivery*, nós adotamos uma abordagem de Diferença-em-Diferenças. Intuitivamente, comparamos a evolução dos rendimentos dos trabalhadores que estavam no mercado formal e, posteriormente, tornaram-se parceiros do *iFood* (grupo de tratamento) com a evolução dos rendimentos dos trabalhadores que se mantiveram no mercado formal de trabalho ao longo de todo o período de análise (grupo de controle). Mais formalmente, estimamos a seguinte especificação de estudo de evento na nossa base de dados formada por trabalhadores pareados:

$$y_{it} = \sum_{\tau=-4}^0 \gamma_{\tau} iFood_{it} + \mu_i + \delta_t + \varepsilon_{it}$$

Em que y_{it} é a nossa variável de resultado e mede o logaritmo do rendimento por hora do trabalhador i no ano t . A variável $iFood_{it}$ é uma variável *dummy* que assume 1 para os trabalhadores tratados que são observados no período do tempo igual a τ e assume 0, caso contrário. Denotamos o ano de 2019, em que trabalhadores parceiros do *iFood* começam a ser observados em nossa base de dados como $\tau = 0$ e os anos de pré-tratamento como $\tau = -1, \dots, -5$. Ou seja, o ano de 2018, que é imediatamente anterior ao tratamento é indexado por $\tau = -1$ e todos



os anos restantes são indexados relativos a esse ano específico. μ_i é o efeito-fixado de trabalhador, δ_t é o efeito-fixado de tempo (ano) e, por último, ε_{it} é o termo de erro.

Na equação (1), o coeficiente γ_τ para $\tau = 0$ mede exatamente o impacto de entrada no *iFood* nos rendimentos dos trabalhadores que se moveram do setor formal para a plataforma de delivery. para $\tau = 0$ mede exatamente o impacto de entrada no *iFood* nos rendimentos dos trabalhadores que se moveram do setor formal para a plataforma de delivery. Esse é o nosso coeficiente de interesse. O pressuposto chave de identificação no contexto do estimador de diferença-em-diferenças é o de tendências paralelas. Esse pressuposto estabelece que na ausência do tratamento, a tendência de rendimentos seria a mesma entre o grupo de tratamento e o grupo de controle. Embora seja um pressuposto não testável por definição, os coeficientes γ_τ de (1) para $\tau < 1$ (conhecidos como efeitos antecipatórios ou leads) são úteis para se ter uma ideia de sua validade. Caso os efeitos antecipatórios sejam estatisticamente significantes, teríamos uma evidência de que mesmo antes do início da plataforma de delivery já havia algum tipo de divergência nos rendimentos dos trabalhadores que formam o grupo de controle e os trabalhadores que se moveram para o *iFood*. Nessa situação hipotética, haveria uma clara violação do nosso pressuposto chave de identificação.

3.4. Resultados


A Figura 3 mostra os resultados da estimação da equação (1) utilizando o método dos mínimos quadrados ordinários. A variável dependente é dada pelo logaritmo do rendimento-hora. A estimação é feita usando as duas formas alternativas de mensurar a quantidade de horas trabalhadas pelos entregadores do *iFood* discutidas na subseção 2.3: a) horas utilizadas na entrega: mensurada como o tempo decorrido entre o início da solicitação de encomenda e a sua efetiva entrega (painel A) e b) tempo estimado conectado à plataforma: mensurado como o tempo em que o entregador se manteve conectado ao aplicativo do *iFood* (painel B). A equação (1) é estimada considerando a inclusão dos efeitos-fixos do indivíduo e do tempo anual.

Inicialmente, a Figura 3 revela que no período anterior à entrada dos trabalhadores na plataforma de *delivery*, os coeficientes associados aos efeitos antecipatórios não são estatisticamente diferentes de zero. Isso revela que, antes de 2019, os trabalhadores que iriam se mover para o *iFood* não possuíam uma trajetória de rendimentos diferente em relação aos rendimentos dos trabalhadores que não se moveram para a plataforma. Essa


evidência sugere a validade do pressuposto chave de tendências paralelas e confirma que a estratégia de pareamento (ver subseção 3.1) é capaz de fornecer um grupo de controle adequado. Já o coeficiente associado ao ano de 2019 no painel A é positivo e estatisticamente significativo, indicando que os trabalhadores formais que se moveram para o *iFood* tiveram um acréscimo de aproximadamente 65,5% em seu rendimento-hora quando comparados a trabalhadores semelhantes que não entraram para a plataforma e continuaram empregados no setor formal tradicional. Entretanto, essa evidência é fortemente sensível com relação à definição adotada para o parâmetro do volume de horas efetivamente trabalhadas dos entregadores do *iFood*. Quando consideramos as horas trabalhadas como iguais à estimativa de horas em que os entregadores estão conectados no aplicativo do *iFood*, o impacto da plataforma cai para -3,5% (painel B). Apesar desse impacto ser estatisticamente significativo, a sua magnitude é pequena.

Figura 3 – O Impacto da participação no IFood sobre o rendimento-hora dos trabalhadores formais que se moveram para a plataforma.

(A) – Horas Trabalhadas: tempo utilizado na entrega



(B) – Horas trabalhadas: tempo estimado conectado à plataforma



Nota: Essa figura mostra a estimação de um estudo de evento (equação (1)) usando intervalos de confiança de 95%. O grupo de tratamento é formado pelos indivíduos que estavam no mercado de trabalho formal em 2018 e moveram-se para o *iFood* em 2019. O grupo de controle é formado por indivíduos que se mantiveram no mercado de trabalho formal tanto em 2018 quanto em 2019.


Diante dessa divergência de resultados, qual seria uma estimativa confiável do impacto do *iFood* sobre o rendimento-hora dos trabalhadores? O cálculo das horas trabalhadas baseado simplesmente nas horas conectadas ao aplicativo provoca uma clara subestimação do efeito porque o entregador pode estar realizando atividades⁵ não diretamente associadas ao *iFood*. Por outro lado, o cálculo das horas trabalhadas com base no tempo decorrido entre a solicitação do pedido e sua efetiva entrega desconsidera qualquer tipo de ociosidade relativa à espera por novas solicitações de encomendas e, sendo assim, superestima o efeito do *iFood*. **Portanto, espera-se que o real efeito da plataforma de *delivery* sobre o rendimento-hora dos trabalhadores que se moveram para o *iFood* esteja justamente no intervalo entre -3,5% a +65,5%. Ou seja, a entrada para a plataforma faz com que os trabalhadores ganhem, no mínimo, praticamente o mesmo rendimento-hora auferido no mercado formal de trabalho.**

Sensibilidade do Impacto do *iFood* em relação ao número de horas trabalhadas

Para obter uma melhor compreensão da relação entre a magnitude do efeito do *iFood* e o volume de horas trabalhadas, a Figura 4 apresenta um gráfico que associa o valor do coeficiente da variável de tratamento em 2019 (eixo vertical) com o crescimento no número de horas trabalhadas (eixo horizontal). Como referência, emprega-se as horas decorridas entre o intervalo da solicitação da encomenda e sua efetiva entrega como “horas efetivamente trabalhadas”. Nota-se que o impacto do *iFood* sobre o rendimento dos indivíduos que se moveram para a plataforma só se torna nulo quando o número de horas trabalhadas aumenta em aproximadamente 206%. **Ou seja, apenas quando o tempo de ociosidade em decorrência da espera por novas solicitações de entrega superar em mais de duas vezes o tempo efetivamente trabalhado (intervalo entre a solicitação e a efetiva entrega da encomenda), o efeito da plataforma de *delivery* se torna nulo.**

⁵ O trabalhador pode manter-se conectado à plataforma do *iFood* mesmo quando está realizando entregas para outras plataformas de *delivery* de encomendas ou quando desfruta de horas de lazer, por exemplo.

Figura 4 – Sensibilidade do impacto do iFood em relação a variações no número de horas trabalhadas pelos entregadores



Nota: A figura mostra a relação entre valor do coeficiente associado ao impacto do iFood em 2019 (Estimado por meio da equação (1)) e a variação no número de horas de trabalho do grupo de tratamento em 2019.

Saída do mercado de trabalho formal

Como discutido na subseção 3.1, nós restringimos o grupo de controle ao considerar apenas aqueles trabalhadores que se mantiveram efetivamente empregados em 2019 (período pós-tratamento). Essa restrição é feita por duas razões: para tornar o grupo de controle comparável ao grupo de trabalhadores tratados e porque as informações referentes aos rendimentos não são observáveis para a parcela de trabalhadores que sai do mercado formal. Caso essa restrição não seja imposta, observa-se que o número de trabalhadores do grupo de controle que sai do mercado formal de trabalho é igual a 5.427 (31,1% dos empregados de controle). Em decorrência da simetria entre o grupo de tratamento e do grupo de controle obtida pelo pareamento, esse número de demissões também seria esperado no grupo de trabalhadores tratados na situação hipotética de não ocorrência de movimentação de trabalhadores para o iFood. Por último, nota-se que a adoção dessa restrição tende a provocar uma subestimação em nossas estimativas do

impacto do *iFood*⁶ sobre os rendimentos, uma vez que uma parcela significativa do grupo de controle efetivamente deixou o mercado de trabalho formal, tornando-se desempregado ou com uma renda proveniente do mercado informal.

Razões para a movimentação de trabalhadores do mercado formal para o *iFood*

Com base na nossa estratégia de rastreamento dos trabalhadores que saíram do mercado formal e tornaram-se parceiros do *iFood* (subseção 3.1) é possível também rastrear as causas da sua demissão e, conseqüentemente, os motivos que estão por trás dessa movimentação. **Assim, observa-se que os principais motivos para a saída do mercado formal são a rescisão sem justa causa por iniciativa do empregador (70,25% dos casos), demissão a pedido do empregado (15,8%) e término de contrato temporário (7,95%).**

Heterogeneidade Regional


É possível que o impacto do *iFood* no rendimento do trabalhador seja heterogêneo entre as diferentes regiões brasileiras. Por exemplo, regiões que possuem maior densidade ou economias de urbanização tendem a fornecer maiores oportunidades para a expansão da plataforma de *delivery* e, assim, possibilitar rendas maiores para os entregadores. Por outro lado, nas regiões maiores e mais densas é esperado uma competição mais intensa entre as plataformas de *delivery* de comida ou entre os próprios entregadores, o que provocaria um impacto negativo na renda auferida pela plataforma. Para avaliar a heterogeneidade do impacto conforme o mercado regional de trabalho, nós estimamos a equação (1) restringindo a amostra total para subconjuntos de regiões específicas.

⁶ Em geral, o trabalho informal remunera menos do que o trabalho formal. Com base nas informações da Pesquisa Nacional por Amostra de Domicílios Contínua (PNAD) de 2020, um trabalhador formal médio tem um rendimento-hora cerca de 32% superior ao rendimento-hora de um trabalhador informal.


Utilizamos um recorte por regiões metropolitanas (RMs) selecionadas⁷ (Figura 5, painel A) e um recorte macrorregional (painel B).

Figura 5 – O impacto da participação no IFood nos rendimentos: heterogeneidades regionais.

(A)– Estimação por Região Metropolitana.



(B) – Estimação por Macrorregião.



⁷ Mais especificamente, utilizamos subamostras para as seguintes regiões metropolitanas (RMs): Porto Alegre, Fortaleza, Recife, Rio de Janeiro, São Paulo, Belém e Distrito Federal e entorno.


Nota: A figura apresenta a estimação de um estudo de evento (equação (1)) usando intervalos de confiança de 95% e incluindo o efeito-fixo de indivíduo e de tempo. Apenas o coeficiente associado ao ano de 2019 (pós-tratamento) é reportado.

A partir da Figura 5 é possível observar que o impacto do *iFood* sobre o rendimento dos trabalhadores que se moveram para a plataforma é positivo e estatisticamente significativo em todas as sete regiões metropolitanas investigadas. É importante destacar que quando se compara as regiões metropolitanas analisadas, o efeito positivo da plataforma é mais intenso nas RMs de médio porte (Porto Alegre, Recife e Fortaleza) do que nas RMs de grande porte (São Paulo e Rio de Janeiro). Já o painel B da Figura 5 mostra que um padrão semelhante quando separamos nossa amostra por macrorregião, o efeito do *iFood* é mais forte para a região sul (com um coeficiente próximo a 0,65) e para a região nordeste (com um coeficiente próximo a 0,55). Já a região norte, apresenta o menor diferencial de rendimento-hora, com um coeficiente de aproximadamente 0,25.


Embora não seja possível explicar o motivo dessas heterogeneidades espaciais entre regiões metropolitanas e entre macrorregiões, é possível perceber que esse padrão decorre predominantemente das diferenças de remuneração do *iFood*, uma vez que os rendimentos-horas médios de trabalhadores formais das diferentes regiões não difere de maneira significativa. Isso pode ser observado através da Figura 6, que mostra a média de rendimento-hora (separada por região metropolitana e por macrorregião) dos entregadores do *iFood* e do respectivo grupo de controle, formado por trabalhadores formais.

Figura 6 – Média de Rendimento-Hora em 2019, trabalhadores iFood e trabalhadores formais, por Região Metropolitana e Macrorregião.

(A) – Média do Rendimento-Hora por Região Metropolitana.



(B) – Estimação por Macrorregião.



Nota: A figura apresenta a média do rendimento-hora separado por região metropolitana e por macrorregião para entregadores do iFood e para trabalhadores do mercado formal.



4. DIFERENCIAL SALARIAL POR CARACTERÍSTICAS INDIVIDUAIS

4.1. Introdução

Detentor de altos níveis de desigualdade socioeconômica, o Brasil possui um mercado de trabalho que contribui fortemente para essas disparidades. Esse mercado é caracterizado por uma ampla desigualdade salarial entre os indivíduos, e diferentes explicações são propostas para esclarecer tal assimetria. Uma das explicações da desigualdade salarial baseia-se na Teoria do Capital Humano desenvolvida por Schultz (1961), em que a diferença salarial pode ser elucidada por meio das habilidades que os indivíduos possuem e adquiriram através de educação, treinamentos e experiências, que impactam a sua produtividade. Outra explicação é fundamentada na Teoria da Discriminação Estatística, retratada nos modelos desenvolvidos por Phelps (1972) e Arrow (1972), em que a diferença salarial é baseada em critérios observáveis dos indivíduos, mas que são irrelevantes para o desenvolvimento da atividade produtiva, tais como gênero, raça, orientação sexual, religião ou nacionalidade.

A diferença salarial entre gêneros ainda é observada na atualidade, mesmo com todos os progressos e realizações conquistados pela inserção das mulheres no mercado de trabalho. Em 2019, a participação das mulheres no mercado aumentou pelo 5º ano consecutivo, porém elas continuam recebendo menos que os homens. De acordo com a segunda edição do estudo Estatísticas de Gênero: indicadores sociais das mulheres no Brasil, divulgado em 2021 pelo IBGE, as mulheres receberam 77,7% do rendimento dos homens (IBGE, 2021). Parte dessa desigualdade pode ser explicada por fatores como a inflexibilidade das horas trabalhadas e pela penalidade da maternidade. Empregos que oferecem para seus trabalhadores horários flexíveis, como os da indústria farmacêutica, são os que mais se aproximam de alcançar a igualdade salarial (Goldin, 2014). Outros estudos sugerem que a disparidade salarial de gênero pode ser parcialmente conferida à penalidade da maternidade, diferenças de gênero nos planos de carreira ou preferências por atributos não monetários em um trabalho, como flexibilidade (Mas & Pallais, 2017),

trabalho em casa e competitividade no local de trabalho (Niederle & Vesterlund, 2007); (Flory, Leibbrandt, & List, 2015).

A desigualdade salarial entre raças é um fenômeno que persiste desde a colonização até os dias atuais. Tal desigualdade atinge grande parte da população, já que a população negra corresponde a 56,3% da população brasileira⁸. Tal contraste de renda ocorre devido a oportunidades educacionais desiguais e remunerações inferiores em posições de trabalho semelhantes. Dados do IBGE mostram que trabalhadores brancos possuem, em média, renda 74% superior em relação a pretos e pardos⁹. Essa diferença de renda prevalece mesmo se os indivíduos tiverem o mesmo nível de educação.

Visto que flexibilidade do local, de horas trabalhadas e atributos pessoais são alguns pontos que podem explicar parte da desigualdade salarial de gênero e racial, tem-se discutido na literatura da economia do trabalho que a *gig economy* oferece a possibilidade de reduzir tais diferenças salariais (Farrell & Greig, 2016). O mercado de aplicativos de entrega vem crescendo, em média 12% ao ano no mundo e, no Brasil, 20%, sendo o desempenho nacional acima da média da maioria dos países¹⁰. O mercado de aplicativos de entrega atua em plataformas online em que atributos pessoais, como gênero ou raça, são dispensáveis para a prestação do serviço. Ou seja, em uma plataforma de pagamentos neutra, não deveria haver qualquer tipo de segregação ou discriminação com relação à remuneração dos atuantes na plataforma.

Contudo, mesmo em um mercado que possui uma plataforma que não esteja estruturalmente configurada para discriminar, ou seja, em que as oportunidades de discriminação, segregação de trabalho e indicações são removidas, devido a “neutralidade” do software, pode ser persistente a diferença de ganhos entre mulheres e homens e entre brancos e não brancos. Um dos estudos pioneiros nesse ramo é a discussão de Adams-Prassl & Berg (2017) que utiliza dados de uma plataforma online de trabalho coletivo onde o sexo dos trabalhadores é desconhecido para o empregador, para avaliar se há uma disparidade salarial de gênero entre os trabalhadores. Nesse cenário foi encontrado uma disparidade salarial entre homens e mulheres, com as mulheres ganhando em média 82% do que os homens ganhavam. No entanto, uma análise mais aprofundada dos dados revelou que a diferença de rendimentos entre homens e mulheres não decorre da utilização da plataforma em si, mas pelas

⁸ <https://www.seade.gov.br/mercado-trabalho/ocupacao-entre-os-negros-diminui-18-no-1o-semester-de-2020/>

⁹ <https://www1.folha.uol.com.br/mercado/2019/11/brancos-tem-renda-74-superior-a-de-pretos-e-pardos-diz-ibge.shtml>

¹⁰ <https://www.consumidormoderno.com.br/2019/06/24/apps-delivery-brasil-2019/>

características individuais do trabalhador (experiência de trabalho coletivo e nível educacional). Cook (2018) também retrata uma diferença salarial de gênero, de aproximadamente 7% na plataforma de viagens compartilhadas da Uber, nos EUA. Em que 36% dessa diferença salarial é explicada pelo fato de que os homens acumulam mais experiência do que as mulheres e 28% por diferenças de gênero em onde dirigir e preferências para velocidade de condução.

Outro estudo pioneiro na discussão da diferença de ganhos entre brancos e não brancos é o de Ge (2016), que verificou que plataformas de viagens compartilhadas, passageiros negros foram submetidos a tempos de espera mais longos e taxas de cancelamento mais altas do que passageiros brancos. Edelman (2017) observou que na plataforma *Airbnb*, os hóspedes com nomes evidentemente afro-americanos eram 16% menos propensos a serem aceitos pelos anfitriões do que hóspedes com nomes idênticos, mas com nomes distintamente brancos. Outra constatação é que anfitriões afro-americanos ganham cerca de 12% a menos que anfitriões brancos.

Desse modo, essa seção busca analisar se é persistente a diferença de ganhos entre mulheres e homens, e entre brancos e não brancos no mercado brasileiro de aplicativos de entregas. Tal análise é realizada examinando dados da plataforma de entrega do *iFood* juntamente com dados da RAIS.

4.2. Dados

Inicialmente, consideramos a base de entregadores ativos na plataforma do *iFood* em algum momento entre 2019-2020, composta por 671.299 trabalhadores. Contudo, uma restrição quanto ao número de entregas foi feita. Foram selecionados os entregadores com 20 ou mais entregas nesse período, e foram descartados os demais entregadores. Com tal restrição, foram selecionados 330.963 entregadores do *iFood*, representando cerca de 40,6% da base inicial. Em seguida, unimos informações dos indivíduos observados em 2018 no mercado formal na base da RAIS, selecionando apenas os trabalhadores presentes em ambas as bases. Tal filtro foi feito através do identificador do trabalhador, o CPF criptografado, o qual identificou todos os indivíduos que estavam presentes tanto no mercado formal em 2018 quanto no *iFood* em 2019-2020, em todo o território nacional. Tal busca encontrou 136.690 trabalhadores observados em ambas as bases e que fizeram ao menos 20 entregas na plataforma entre 2019-2020.



4.3. Estratégia Empírica

Para analisar o diferencial salarial desses indivíduos, optamos pelo método de regressão linear simples para uma equação Minceriana¹¹ de determinação de salários. O método foi selecionado, pois estima os diferenciais salariais controlando para as características observáveis, tais como escolaridade, experiência, setor de atuação e cargo de cada indivíduo.

Foram realizadas duas regressões salariais, uma em

que a variável de tratamento utilizada na equação foi o salário/hora dos trabalhadores quando atuavam no mercado formal, e outra onde tal variável era o salário-hora quando esses mesmos indivíduos trabalhavam no *iFood*. As variáveis de controle incluídas na regressão foram as características individuais observadas na RAIS, isso é, sexo, idade, raça, escolaridade, deficiência, setor, ocupação e município de trabalho. Formalmente, as estimações podem ser descritas pelas seguintes equações:

$$y_{i'2018} = \beta_{MF} X_{i'2018} + \varepsilon_{i,2018} \quad (2)$$

$$y_{i'2019-20} = \beta_{IFOOD} X_{i'2018} + \varepsilon_{i,2019-20} \quad (3)$$

A primeira equação (2) estima a regressão salarial para o mercado formal e é composta por $y_{i'2018}$ que mede o logaritmo do rendimento por hora dos trabalhadores no mercado formal em 2018, β_{MF} é o vetor de coeficientes de interesse no mercado formal, $X_{i'2018}$ é um vetor com as características individuais do trabalhador em 2018, incluindo sexo, raça,

¹¹ Apresentada por Jacob Mincer, a equação minceriana estima os salários de um trabalhador por meio de uma equação com o logaritmo do salário/horas do trabalhador como variável dependente e um conjunto de atributos produtivos como variáveis independentes (Mincer, 1974).

escolaridade, idade, ocupação e setor, por fim, $\varepsilon_{i,2018}$ é o termo de erro. Já a segunda equação (3) estima a regressão salarial na plataforma do *iFood* e é composta por $y_{i,2019-20}$ que representa o logaritmo do rendimento por hora dos trabalhadores na plataforma do *iFood* entre 2019 e 2020, β_{iFood} é o vetor de coeficientes de interesse que avalia a associação das mesmas variáveis com o novo salário-hora dos indivíduos.

4.4. Resultados e discussão

A Tabela 2 apresenta os resultados das regressões descritas pelas equações (2) e (3). A coluna (1) apresenta os resultados do modelo estimado para a remuneração observada no mercado formal. Controlando para todos os fatores observáveis, constatou-se que as mulheres da amostra ganhavam, por hora trabalhada, 5,64% a menos que os homens no mercado formal. Com relação à raça, negros recebiam 0,63% a menos do que os brancos e outras raças e etnias recebiam 1,91% a menos. Por fim, os resultados da coluna (1) confirmam que no mercado tradicional, há um grande diferencial de salário por idade e por nível educacional, com a remuneração aumentando conforme o envelhecimento dos trabalhadores e um adicional médio de remuneração de 10,69% para os trabalhadores com ensino superior completo.

Já no *iFood*, os resultados da coluna (2) indicam que as diferenças salariais são atenuadas, tornando-se não significativas para diversas características. Ainda assim, são observadas algumas diferenças residuais, tais como uma remuneração 1,38% menor para as mulheres e 0,53% inferior para os negros. Entretanto, a coluna (3) revela que uma vez que a utilização de moto nas entregas é incluída na regressão como controle, tais diferenciais deixam de ser significativos. Isso ocorre porque a remuneração média por hora trabalhada é maior para as entregas feitas de moto, e tanto mulheres como trabalhadores não brancos apresentam uma menor taxa de utilização desse modal conforme ilustrado na Figura 8

Os resultados das regressões são também apresentados visualmente na Figura 7, que ilustra de forma clara que, para praticamente todas as variáveis, os diferenciais salariais observados no mercado formal são atenuados e inexistentes na plataforma do *iFood*, principalmente quando controlamos para o diferencial de remuneração por modal. **Com tais resultados, evidenciamos que, na plataforma do *iFood*, o diferencial salarial deixa de existir com relação ao gênero e sugere que efeito semelhante ocorre com relação à raça, o que corrobora com a hipótese de que a *gig economy*, tende a diminuir as disparidades salariais por meio de sistemas de pagamentos “neutros”, ou**

seja, em que as oportunidades de discriminação, segregação de trabalho e indicações são removidas. Todavia, mesmo que não seja um diferencial salarial expressivo, ele é extremamente importante. Pois demonstra que o mercado está caminhando para uma mudança, mesmo que com pequenos passos.

A persistência de diferenças salariais na versão não controlada do modelo (Coluna (2)) está em linha com a literatura sobre tais discrepâncias na *gig economy*. Os estudos recentes sugerem que a persistência de diferenciais salariais decorrem não das plataformas em si, mas por características individuais dos trabalhadores, tais como o acesso a recursos de capital (motocicleta e acesso a celular com plano de internet móvel) e a auto seleção associada a diferentes características individuais devido a diferentes preferência por horário ou região de atuação, o que pode levar a tais grupos a apresentar níveis diferentes de remuneração mesmo que tais diferenças não violem a neutralidade do algoritmo de pagamento.


Tabela 2 – Determinantes salariais, RAIS 2018 e iFood 2019-2020

Variável	diferencial salarial			
	mercado formal (RAIS)	iFood		
	(1)	(2)	(3)	
Mulher	-0,0564 (0,0044) ***	-0,0138 (0,0055) *	0,0045	(0,0038)
Deficiência Física	0,0153 (0,0085)	0,0007 (0,0107)	0,0065	(0,0107)
Moto			0,0835	(0,0244) ***
<i>Cor/raça</i> ¹				
Negro	-0,0063 (0,0030) *	-0,0053 (0,0026) *	-0,0018	(0,0026)
Pardo	-0,0019 (0,0023)	-0,0033 (0,0016) *	-0,0020	(0,0017)
Outras Raças/Etnias	-0,0191 (0,0035) ***	-0,0001 (0,0025)	0,0012	(0,0024)
<i>Idade</i> ²				
16-18	-0,1697 (0,0055) ***	-0,0164 (0,0088)	-0,0055	(0,0072)
18-20	-0,0806 (0,0030) ***	-0,0061 (0,0031) *	-0,0044	(0,0029)
25-30	0,0761 (0,0041) ***	0,0009 (0,0024)	-0,0004	(0,0024)
30-35	0,1210 (0,0058) ***	0,0044 (0,0025)	0,0024	(0,0028)
35-40	0,1419 (0,0058) ***	-0,0045 (0,0038)	-0,0052	(0,0041)
40-50	0,1569 (0,0060) ***	-0,0041 (0,0036)	-0,0024	(0,0037)
50-60	0,1884 (0,0131) ***	-0,0177 (0,0092)	-0,0118	(0,0093)
60-120	0,1340 (0,0266) ***	0,0663 (0,0474)	0,0763	(0,0480)
<i>Ensino</i> ³				
Infantil Completo	-0,0032 (0,0100)	0,0146 (0,0055) **	0,0166	(0,0055) **
Fundamental Completo	-0,0178 (0,0076) *	0,0036 (0,0032)	0,0054	(0,0029)
Superior Completo	0,1069 (0,0050) ***	-0,0123 (0,0033) ***	-0,0132	(0,0033) ***
<i>Efeitos fixos</i>				
Município	sim	sim	sim	
Setor (2018)	sim	sim	sim	
Ocupação (2018)	sim	sim	sim	
Observações	132.568	132.568	132.568	
R ²	0,396	0,128	0,136	

Notas: * p < 0.05, ** p < 0.01, *** p < 0.001


Grupos de referência: ¹ ensino médio completo; ² brancos; ³ idade entre 21-24 anos.

Figura 7 – Determinantes salariais, RAIS 2018 e iFood 2019-2020



Nota: A figura apresenta visualmente os coeficientes e intervalos de confiança apresentados na Tabela 2.

Figura 8 – Utilização de motocicleta nas entregas do iFood por gênero e por raça



Nota: base de rotas do iFood

Antigamente, acreditava-se que o comércio baseado em algoritmos poderia reduzir os efeitos da discriminação salarial entre gêneros e racial, visto que o papel dos humanos é

minimizado nesse tipo de transação. Em vez disso, Fisman & Luca (2016) dizem que a confiança em algoritmos, em muitos casos, pode alimentar, em vez de suprimir a discriminação. Com a análise feita, vimos que, na plataforma do *iFood*, já encontramos uma redução significativa nos diferenciais salariais de gênero. O mesmo não pode ser verificado no que se refere aos diferenciais raciais, principalmente por falta de poder estatístico da análise. **Algo que pode ser feito pelas plataformas para diminuir tais discriminações é ter um maior conhecimento da composição racial e de gênero de seus colaboradores na plataforma e fazer ajustes que erradiquem discrepâncias salariais e não salariais. No início, testemunhamos o potencial da Internet e da *gig economy* para criar mercados livres de considerações de raça, gênero e idade. Agora, com toda evolução e conhecimento, espera-se que as plataformas usem seu poder para criar uma economia mais inclusiva e com menos disparidades salariais de gênero e de raça.**

BIBLIOGRAFIA

Adams-Prassl, A., & Berg, J. (4 de October de 2017). When Home Affects Pay: An Analysis of the Gender Pay Gap Among Crowdworkers. *SRN Electronic Journal*.

Arrow, K. J. (Sep de 1972). Models of job discrimination. A.H. Pascal, ed. *Racial Discrimination in Economic Life*, pp. 83–10.

Cook, C. D. (2018). The Gender Earnings Gap in the Gig Economy: Evidence from over a Million Rideshare Drivers. *NBER Working Papers, National Bureau of Economic Research*.

Edelman, B. M. (April de 2017). Racial Discrimination in the Sharing Economy: Evidence from a Field Experiment. *American Economic Journal: Applied Economics*, pp. 1-22.

Farrell, D., & Greig, F. (2016). Paychecks, paydays, and the online platform economy: Big data on income volatility. *Household Finance eJournal*.

Fisman, R., & Luca, M. (December de 2016). Fixing Discrimination in Online Marketplaces. *Harvard Business Review*, pp. 88–95.

Flory, J., Leibbrandt, A., & List, J. (2015). Do Competitive Workplaces Deter Female Workers? A Large-Scale Natural Field Experiment on Job Entry Decisions. *Review of Economic Studies*, pp. 122-155.

Ge, Y. a. (October de 2016). Racial and Gender Discrimination in Transportation Network Companies. *Working Paper*.

Goldin, C. (April de 2014). A Grand Gender Convergence: Its Last Chapter. *AMERICAN ECONOMIC REVIEW*, pp. 1091-1119.

IBGE. (2021). *Estatísticas de Gênero Indicadores sociais das mulheres no Brasil*. IBGE.

Mas, A., & Pallais, A. (December de 2017). Valuing Alternative Work Arrangements. *AMERICAN ECONOMIC REVIEW*, pp. 3722-59.

Mincer, J. A. (1974). The Human Capital Earnings Function. *NBER*, 83-96.

Niederle, M., & Vesterlund, L. (2007). Do Women Shy Away From Competition? Do Men Compete Too Much? *The Quarterly Journal of Economics*, pp. 1067-1101.

Nunes, L. C., & Ferrari, M. J. (2019). Custo da Prestação de Serviço de Entrega de Jornal. *XXVI Congresso Brasileiro de Custos*.

OECD. (2019). *Gig economy platforms: Boon or Bane?* OECD.

Phelps, E. S. (Sep de 1972). The Statistical Theory of Racism and Sexism. *The American Economic Review*, pp. 659-661.

Schultz, T. W. (March de 1961). Investment in human capital. *The American Economic Review*, pp. 1-17.

news.
ifood.
com.br

